

Уральский федеральный университет имени первого Президента России Б.Н. Ельцина

**Л.Г. Доросинский, Н.С. Виноградова, О.Ю. Иванов**

# **ОБРАБОТКА РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ**

Монография

Москва  
2021

УДК 621.312.01(076)

ББК 32.88

Д69

***Рецензенты:***

**Иванов Вячеслав Элизбарович** — доктор технических наук, профессор;

**Часовских Виктор Петрович** — доктор технических наук, профессор.

Д69

**Доросинский Л.Г., Виноградова Н.С., Иванов О.Ю.**

Обработка радиолокационных изображений: монография / Л.Г. Доросинский, Н.С. Виноградова, О.Ю. Иванов. — М.: Издательский дом Академии Естествознания, 2021. — 334 с.

**ISBN 978-5-91327-714-5**

**DOI 10.17513/np.503**

Книга посвящена решению теоретических и практических проблем обнаружения, измерения параметров и классификации пространственно-распределённых целей (ПРЦ) по их радиолокационным изображениям (РЛИ), формируемым в многопозиционной системе наблюдения, реализованной группой космических аппаратов.

В книге подробно рассмотрены методы синтеза и анализа алгоритмов классификации ПРЦ, алгоритмы оценки параметров РЛИ, алгоритмы классификации с использованием нейронных сетей, частично-когерентных РЛС, алгоритмы формирования РЛИ движущихся объектов, методы фильтрации спекл-шума, методы анализа помехоустойчивости, методы геокоррекции формируемых РЛИ.

Книга представляет интерес для специалистов, студентов и аспирантов, работающих в области разработки современных радиотехнических систем военного и гражданского назначения.

**ISBN 978-5-91327-714-5**

© Доросинский Л.Г., Виноградова Н.С.,  
Иванов О.Ю., 2021

© ИД «Академия Естествознания»

© АНО «Академия Естествознания»

---

## ОГЛАВЛЕНИЕ

|   |    |
|---|----|
| ВВЕДЕНИЕ. ОСНОВНЫЕ МЕТОДЫ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ .....                             | 7  |
| В.1. История дистанционного зондирования Земли из космоса [1].....                      | 7  |
| В.2. Техника получения материалов дистанционного зондирования.....                      | 9  |
| В.3. РЛС с синтезированной апертурой .....  | 10 |
| В.4. Литература к главе «Введение» .....  | 13 |
| 1. РАСПОЗНАВАНИЕ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ<br>(СОВРЕМЕННОЕ СОСТОЯНИЕ ПРОБЛЕМЫ) ..... | 14 |
| 1.1. Формирование вспомогательных дешифровочных признаков .....                         | 14 |
| 1.1.1. Фурье-преобразование .....   | 15 |
| 1.1.2. Преобразование Радона .....  | 15 |
| 1.1.3. Преобразование Хафа.....   | 15 |
| 1.1.4. Вейвлет-преобразование .....   | 15 |
| 1.2. Методы снижения размерности .....  | 16 |
| 1.2.1. Метод главных компонент .....  | 16 |
| 1.2.2. Метод независимых компонент .....  | 17 |
| 1.2.3. Низкоранговое матричное разложение .....   | 17 |
| 1.3. Классификация без обучения .....   | 17 |
| 1.3.1. Пороговая обработка .....  | 18 |
| 1.3.2. Кластеризация .....  | 19 |
| 1.3.3. Нарращивание областей .....  | 20 |
| 1.3.4. Выделение границ .....   | 21 |
| 1.3.5. Модель активного контура .....   | 21 |
| 1.3.6. Скрытые марковские поля .....  | 22 |
| 1.3.7. Вывод по разделу 1.3 .....   | 23 |
| 1.4. Классические методы .....  | 24 |
| 1.4.1. Байесовский классификатор.....   | 24 |
| 1.4.2. Дискриминантный анализ .....   | 26 |
| 1.4.3. Логистическая регрессия.....   | 26 |
| 1.4.4. Постоянная вероятность ложных тревог .....                                       | 26 |
| 1.4.5. Вывод по разделу 1.4.....  | 28 |
| 1.5. Классификация с обучением .....  | 28 |
| 1.5.1. Взаимная корреляционная функция .....  | 29 |
| 1.5.2. Расстояние Махаланобиса .....  | 29 |
| 1.5.3. Метод $k$ -ближайших соседей .....   | 30 |
| 1.5.4. Метод опорных векторов .....   | 30 |
| 1.5.5. Метод разреженных представлений .....  | 31 |
| 1.5.6. Дерево решений .....   | 32 |
| 1.5.7. Модель ASC .....   | 32 |
| 1.5.8. Выводы по разделу 1.5 .....  | 33 |
| 1.6. Глубокое обучение .....  | 33 |
| 1.6.1. Свёрточные нейронные сети .....  | 34 |
| 1.6.2. Автокодировщики .....  | 36 |

---

|        |   |            |
|--------|---|------------|
| 1.6.3. | Ограниченная машина Больцмана .....   | 36         |
| 1.6.4. | Глубокая сеть доверия .....   | 37         |
| 1.6.5. | Рекуррентные нейронные сети .....   | 37         |
| 1.6.6. | AdaBoost .....  | 38         |
| 1.6.7. | Генетический алгоритм.....  | 39         |
| 1.6.8. | Вывод по разделу 1.6.....   | 40         |
| 1.7.   | Выводы к главе 1 .....  | 40         |
| 1.8.   | Литература к главе 1.....   | 41         |
| 2.     | <b>РАДИОЛОКАЦИОННЫЕ СИСТЕМЫ ДИСТАНЦИОННОГО<br/>ЗОНДИРОВАНИЯ ЗЕМЛИ .....</b>   | <b>58</b>  |
| 2.1.   | ALOS .....  | 58         |
| 2.2.   | COSMO-SkyMed .....  | 62         |
| 2.3.   | ERS .....   | 65         |
| 2.4.   | Envisat .....   | 68         |
| 2.5.   | RADARSAT.....   | 72         |
| 2.6.   | Sentinel.....   | 80         |
| 2.7.   | TerraSAR-X .....  | 84         |
| 2.8.   | TanDEM-X.....   | 84         |
| 2.9.   | PAZ .....   | 86         |
| 2.10.  | Малые космические аппараты .....  | 88         |
| 2.11.  | Основы распознавания пространственно-распределённых целей.....  | 92         |
| 2.12.  | Литература к главе 2.....   | 95         |
| 3.     | <b>КЛАССИФИКАЦИЯ ПРЦ ПО ДАННЫМ КОСМИЧЕСКОЙ РЛС БОКОВОГО<br/>ОБЗОРА С СИНТЕЗИРОВАННОЙ АПЕРТУРОЙ .....</b>  | <b>101</b> |
| 3.1.   | Математическая модель цели и отражённого сигнала при решении задач<br>распознавания пространственно-распределённых целей в космических<br>РЛС с синтезированной апертурой ..... | 101        |
| 3.2.   | Многоальтернативная проверка гипотез относительно различных<br>классов ПРЦ при их наблюдении совокупностью космических<br>радиолокационных средств .....                        | 106        |
| 3.3.   | Адаптивный алгоритм классификации пространственно-распределённых<br>целей по данным радиолокатора с синтезированной апертурой .....   | 110        |
| 3.4.   | Алгоритмы автоматического группирования данных .....  | 118        |
| 3.4.1. | Чёткая и нечёткая декомпозиции .....  | 118        |
| 3.4.2. | Алгоритмы декомпозиции.....   | 121        |
| 3.5.   | Литература к главе 3.....   | 125        |
| 4.     | <b>АНАЛИЗ АЛГОРИТМОВ КЛАССИФИКАЦИИ<br/>ПРОСТРАНСТВЕННО-РАСПРЕДЕЛЁННЫХ ЦЕЛЕЙ ПО ДАННЫМ РСА ....</b>  | <b>126</b> |
| 4.1.   | Границы Чернова и Кайлата — метод определения потенциальных<br>возможностей классификации ПРЦ по вектору наблюдаемых данных .....   | 126        |
| 4.2.   | Анализ потенциальных характеристик классификации ПРЦ<br>по вектору наблюдаемых данных .....   | 131        |
| 4.3.   | Методика расчета эффективности классификации ПРЦ<br>по радиолокационному портрету .....   | 136        |
| 4.3.1. | Проблема анализа эффективности алгоритмов классификации .....   | 136        |



---

|        |  |     |
|--------|--|-----|
| 4.3.2. | Вывод расчетных выражений для оценки вероятностей правильных и ошибочных решений при классификации ПРЦ по РЛИ .....                                      | 139 |
| 4.3.3. | Оценка эффективности при корнях большой кратности .....  | 147 |
| 4.4.   | Анализ алгоритмов классификации по РЛИ ПРЦ .....   | 148 |
| 4.5.   | Распознавание ПРЦ по данным разных средств наблюдения .....  | 151 |
| 4.5.1. | Коллективное распознавание .....   | 151 |
| 4.5.2. | Анализ эффективности классификации .....   | 153 |
| 4.6.   | Методика расчета вероятности правильного распознавания при объединении решений отдельных СН методом простого голосования .....                           | 155 |
| 4.7.   | Литература к главе 4 .....   | 157 |
| 5.     | КЛАССИФИКАЦИЯ ПРЦ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ .....   | 158 |
| 5.1.   | Общие принципы построения нейронной сети (НС) .....  | 158 |
| 5.2.   | Алгоритм обратного распространения ошибки .....  | 161 |
| 5.3.   | Нейронные сети и их применение в задачах распознавания РЛИ .....   | 165 |
| 5.4.   | Оценка ракурса (ориентации) ПРЦ с помощью нейронных сетей .....  | 172 |
| 5.5.   | Классификация ПРЦ по интенсивности .....   | 174 |
| 5.6.   | Литература к главе 5 .....   | 177 |
| 6.     | ОБНАРУЖЕНИЕ СИГНАЛОВ В ЧАСТИЧНО-КОГЕРЕНТНЫХ РСА .....  | 178 |
| 6.1.   | Постановка задачи .....  | 178 |
| 6.2.   | Анализ эффективности обнаружения .....   | 180 |
| 6.3.   | Литература к главе 6 .....   | 184 |
| 7.     | ИЗМЕРЕНИЕ ПАРАМЕТРОВ РЛИ .....   | 185 |
| 7.1.   | Измерение общегрупповых параметров распределенной цели. Измерение координат центра РЛИ .....   | 185 |
| 7.1.1. | Синтез оптимального измерителя общегруппового параметра групповой цели .....   | 185 |
| 7.1.2. | Анализ эффективности алгоритма измерения координаты центра ПРЦ .....   | 189 |
| 7.2.   | Оценка области, занимаемой целью на РЛИ .....  | 192 |
| 7.3.   | Оценка ракурса цели .....  | 197 |
| 7.4.   | Анализ алгоритмов оценки координат граничных точек между областями РЛИ с отличающимся контрастом .....   | 198 |
| 7.5.   | Межобзорная идентификация РЛИ ПРЦ .....  | 202 |
| 7.6.   | Оценка радиолокационного портрета ПРЦ .....  | 205 |
| 7.7.   | Компенсация отражений от источников помех .....  | 207 |
| 7.7.1. | Разработка алгоритма .....   | 207 |
| 7.7.2. | Анализ алгоритма .....   | 210 |
| 7.8.   | Интерферометрические РСА для измерения высот целей .....   | 213 |
| 7.9.   | Литература к главе 7 .....   | 217 |
| 8.     | АНАЛИЗ ЭФФЕКТИВНОСТИ АЛГОРИТМОВ ОБНАРУЖЕНИЯ ИЗМЕНЕНИЙ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ ПОВЕРХНОСТИ В МНОГОПОЗИЦИОННОЙ СИСТЕМЕ КОСМИЧЕСКОГО МОНИТОРИНГА ..... | 219 |
| 8.1.   | Синтез алгоритма классификации .....   | 222 |

---

|         |   |            |
|---------|---|------------|
| 8.2.    | Анализ эффективности классификации при комплексировании наблюдений разными спутниками.....                      | 229        |
| 8.3.    | Классификация неоднородных РЛИ .....  | 233        |
| 8.4.    | Литература к главе 8.....   | 237        |
| 9.      | <b>ОСОБЕННОСТИ ПОЛУЧЕНИЯ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ ДВИЖУЩИХСЯ ПРОСТРАНСТВЕННО-РАСПРЕДЕЛЕННЫХ ЦЕЛЕЙ .....</b> | <b>238</b> |
| 9.1.    | Искажение РЛИ при движении ПРЦ .....  | 238        |
| 9.2.    | Литература к главе 9.....   | 248        |
| 10.     | <b>ФИЛЬТРАЦИИ СПЕКЛ-ШУМА.....</b>   | <b>249</b> |
| 10.1.   | Математическая модель и статистические характеристики когерентных РЛИ протяженных целей.....                    | 250        |
| 10.2.   | Характеристики реальных РЛИ протяженных целей.....  | 254        |
| 10.3.   | Модель радиолокационного изображения точечной цели .....  | 256        |
| 10.4.   | Классификация алгоритмов фильтрации спекл-шума .....  | 256        |
| 10.4.1. | Суммирование независимых РЛИ .....  | 258        |
| 10.4.2. | Локальные алгоритмы обработки РЛИ.....  | 263        |
| 10.5.   | Моделирование работы алгоритмов фильтрации спекл-шума.....  | 267        |
| 10.5.1. | Снижение уровня спекл-шума.....   | 267        |
| 10.5.2. | Ухудшение пространственного разрешения .....  | 268        |
| 10.5.3. | Моделирование работы фильтра Фроста.....  | 269        |
| 10.6.   | Результаты обработки реальных РЛИ .....   | 272        |
| 10.7.   | Методика выбора фильтра и его параметров.....   | 278        |
| 10.8.   | Литература к главе 10.....  | 279        |
| 11.     | <b>АНАЛИЗ ПОМЕХОУСТОЙЧИВОСТИ РЛС С СИНТЕЗИРОВАННОЙ АПЕРТУРОЙ.....</b>   | <b>281</b> |
| 11.1.   | Вывод основных соотношений .....  | 281        |
| 11.2.   | Расчёт зон подавления и коэффициентов улучшения .....   | 285        |
| 11.3.   | Литература к главе 11 .....   | 289        |
| 12.     | <b>ГЕОКОРРЕКЦИЯ ИЗОБРАЖЕНИЙ.....</b>  | <b>290</b> |
| 12.1.   | Причины появления геометрических искажений.....   | 290        |
| 12.2.   | Методы коррекции геометрических искажений .....   | 295        |
| 12.3.   | Оценка точности геометрической коррекции .....  | 301        |
| 12.4.   | Пересчет раstra.....  | 302        |
| 12.5.   | Метод ближайшего соседа.....  | 303        |
| 12.6.   | Алгоритм, основанный на преобразовании «резиновый лист» .....   | 309        |
| 12.7.   | Триангуляция .....  | 310        |
| 12.8.   | Трансформирование на основе треугольника .....  | 311        |
| 12.9.   | Литература к главе 12.....  | 313        |
| 13.     | <b>ВЫДЕЛЕНИЕ ЛИНЕЙНЫХ ЭЛЕМЕНТОВ НА РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЯХ .....</b>                                      | <b>315</b> |
| 13.1.   | Методы выделения линейных структур.....   | 316        |
| 13.2.   | Алгоритм, основанный на преобразовании Хаффа .....  | 318        |
| 13.3.   | Пример обработки реального изображения .....  | 330        |
| 13.4.   | Литература к главе 13.....  | 332        |

---

***Дорогому ИРИТ-РТФ  
в год его 70-летия  
с благодарностью и любовью!***

## **ВВЕДЕНИЕ. ОСНОВНЫЕ МЕТОДЫ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ**

Проблема обнаружения, оценки параметров и классификации пространственно-распределённых целей была и остаётся определяющей при разработке и создании современных радиолокационных систем мониторинга космической, воздушной и наземной обстановки современными и перспективными радиолокационными средствами.

В настоящей работе названная проблема решается, как задача наблюдения наземных и надводных целей космическими системами с высоким разрешением по дальности и азимуту (РЛС с синтезированной апертурой).

В работе приведены основные сведения из области принятия оптимальных решений: метод максимального правдоподобия, параметрический и непараметрический методы оценивания параметров, которые носят общетеоретический характер.

Кроме того, получены модели принимаемых сигналов, синтезированы оптимальные и предложены квазиоптимальные (практически реализуемые) алгоритмы обнаружения сигналов от пространственно-распределённых целей, алгоритмы оценивания параметров названных сигналов, а также алгоритмы классификации целей по отражённым сигналам.

В работе получены необходимые выражения для определения эффективности обнаружения, оценивания и классификации и произведены соответствующие вычисления, что позволяет сформулировать практические рекомендации по выбору параметров используемых сигналов.

Каждая глава монографии носит вполне законченный характер и может рассматриваться отдельно от общего текста. В связи с этим библиографический список приводится отдельно к каждой главе работы.

Настоящая монография будет полезна разработчикам и исследователям современных радиолокационных систем различного назначения, предназначенных для эффективной обработки сигналов от пространственно-распределённых целей, а также аспирантам и студентам, изучающим современные радиотехнические системы.

### **В.1. История дистанционного зондирования Земли из космоса [1]**

Дистанционное зондирование Земли (ДЗЗ) — это широко распространённый метод извлечения информации о поверхности Земли и объектах на ней, атмосфере, океане, верхнем слое земной коры такими способами, когда регистрирующая аппаратура удалена от объекта наблюдения на значительное расстояние и размещена на движущемся носителе — летательном аппарате (ЛА): искусственном спутнике Земли, самолёте, беспилотном ЛА и др. [1, 3, 4]. При дистанционном

зондировании существует функциональная связь между физическими параметрами, характеризующими состояние наблюдаемой поверхности, и регистрируемыми аппаратурой наблюдения вторичными параметрами собственного или отраженного излучения объекта. Измеряемые параметры электромагнитного излучений/отражения от поверхности после соответствующей обработки позволяют сделать практически полезные выводы о состоянии поверхности и прогнозировать названное состояние в интересах самых различных областей знаний.

Исторически первыми аппаратными средствами дистанционного зондирования служила фотография. Начиная со второй половины XX века доминирующую роль в области ДЗЗ стали играть космические средства наблюдения, такие, в частности, как разведывательные спутники (программы CORONA, ARGON, LANYARD), получающие фотоснимки земной поверхности с низких орбит.

В апреле 1960 первый метеорологический спутник был запущен в США 1 апреля 1960 года. Он использовался для прогноза погоды, наблюдения за перемещением циклонов и других подобных задач. Первым среди спутников, которые применялись для регулярной съемки больших участков земной поверхности, стал

Первым спутником для систематической съёмки больших участков поверхности стал TIROS-1 {Television and Infrared Observation Satellite). Для целей сельского хозяйства в 1972 году был запущен спутник ERTS-1 (Earth Resources Technology Satellite). Такого рода спутники используются и в настоящее время (серия Landsat).

В 1978 году, был запущен первый спутник со сканирующей системой SEASAT. Первый французский спутник (SPOT) выведен на орбиту в 1985 году. Далее состоялись запуски индийского и японского спутников. Уже в 1975 году состоялся запуск Китайского спутника.

Отметим основные тенденции развития космического зондирования.

- Разрешение космических снимков, полученных в метровом и дециметровом диапазоне волн, становится близким к фотоснимкам.
- Растёт удельный вес цифровых методов обработки и формирования снимков поверхности.
- Независимость радиолокационных методов наблюдения от времени суток и погодных условий делает названные методы широко используемыми и основными методами ДЗЗ.
- Растёт число коммерческих аппаратов: Landsat(США), SPOT (Франция), IRS(Индия), ALOS (Япония), Cartosat (Индия), спутники сверхвысокого разрешения Ikonos, QuickBird, GeoEye (США), в том числе радиолокационные TerraSAR-X, TanDEM-X, RapidEye (Германия).

Данные спутников комплексировются с другими источниками информации, включая, так называемые, подспутниковые наблюдения.

Стереосъёмка даёт возможность формировать трёхмерное изображение наблюдаемого объекта.

Многозональная и гиперспектральная съёмка позволяют повысить эффективность дешифрирования изображения земной и водной поверхностей.

Многовременная съёмка — съёмка в заранее определенные даты для сравнительного анализа изображений изменяющихся во времени.

Многополяризационная съёмка использует поляризационные отличия отражений от разных типов поверхностей.

## **В.2. Техника получения материалов дистанционного зондирования**

При формировании изображений различных поверхностей используют разные спектральные диапазоны — световой, тепловой и радиодиапазон [2–4].

На световых снимках отображаются оптические характеристики объектов.

Использование приемников теплового излучения (тепловая съемка) позволяет получить тепловые инфракрасные снимки.

Съемка в радиодиапазоне делится на пассивную (регистрация собственного излучения исследуемых объектов) и активную (регистрация отраженного радиоизлучения).

Радиолокационная съемка формирует изображения земной поверхности независимо от погодных условий, в дневное и ночное время благодаря принципу активной радиолокации.

Радиолокационная съемка Земли ведется в различных диапазонах длин волн (1 см — 1 м) или частот (40 ГГц — 300 МГц).

Радиолокационная информация особенно эффективна для целей картографирования территорий, преимущественно закрытых облачностью. В этом случае радиолокационные изображения существенно превосходят оптические.

При использовании информации о разности фаз отражённых сигналов сигналов (радиолокационная интерферометрия) удаётся формировать карты высот элементов поверхности (спутники Cosmo-Skymed, TerraSAR-X, TanDEM-X определяют высоты с относительной точностью менее 2 м).

Температурные неоднородности поверхности Земли, возникающие в результате неодинакового нагрева различных ее участков, являются источником информации при съёмке в инфракрасном диапазоне спектра электромагнитных колебаний. На ИК-изображениях светлыми тонами фиксируются участки с низкими температурами, темными — с относительно более высокими. Яркость тона прямо пропорциональна интенсивности тепловой аномалии.

ИК-съемка может использоваться для изучения рельефа дна шельфа. Поскольку температура поверхности воды над более глубокими участками ниже, чем над мелкими, ИК-изображения дают возможность выделять формы рельефа дна.

Методы ДЗЗ позволяют существенно повысить эффективность картографирования земельных и водных ресурсов, почв, лесов, сельскохозяйственных посевов и городской инфраструктуры, оценки урожая и многое другое.

Примерами эффективного использования технологий дистанционного зондирования может служить краткий перечень отраслей их использования:

1. Землепользование и картографирование земельных ресурсов.
2. Исследования роста городов.
3. Сельское хозяйство.
4. Картографирование грунтовых вод.
5. Борьба с наводнениями.
6. Гидроморфологические исследования.
7. Картографирование пустующих земель.
8. Региональное планирование.
9. Борьба с природными катастрофами.

### **В.3. РЛС с синтезированной апертурой**

Радиолокатор с синтезированной апертурой (РСА) – это активный датчик, излучающий импульсный радиолокационный сигнал, оптимальная обработка которого на борту летательного аппарата позволяет получить радиолокационное изображение (РЛИ) подстилающей поверхности с высоким разрешением по дальности, благодаря широкополосности используемого сигнала и по азимуту за счёт, так называемого, процесса искусственного синтеза апертуры антенны. Эффект искусственного синтеза антенны создаётся вследствие когерентного накопления сигнала на достаточно протяжённом участке траектории полёта ЛА (порядка единиц километров). При таком размере раскрытия антенны в дециметровом диапазоне длин электромагнитных волн разрешение по двум координатам может достигать величин порядка единиц метров [3, 4].

Принцип синтезированной апертуры основан на приеме сигнала от одной и той же точки местности на протяжении достаточно длительного участка полета носителя РСА. При таком способе приема сигнала получается искусственное увеличение (синтезирование) линейного раскрытия антенны за счет движения носителя.

Дополнительный эффект получения не только яркостных карт наблюдаемых участков местности, но и карт распределения высот этих участков обеспечивает интерферометрия – инструмент построения цифровых моделей рельефа поверхности.

Радиолокационные изображения, формируемые в РСА, позволяют решать следующие задачи.

- получение карт труднодоступных территорий, в том числе, покрытых густой растительностью;
- обновление элементов содержания топографических карт;
- построение цифровых моделей рельефа (ЦМР);
- мониторинг ледовой обстановки в арктических морях с целью уточнения положения береговой линии морей и обеспечения судоходства в сложных метеоусловиях;
- оперативный контроль морских экономических зон и районов хозяйственной деятельности;
- мониторинг чрезвычайных ситуаций (последствия стихийных бедствий и техногенных катастроф на море и на суше).

Среди большого количества задач, решаемых по радиолокационным изображениям земной поверхности, в настоящей работе мы сосредоточим основное внимание на задачах распознавания пространственно-распределённых объектов, другими словами пространственно-распределённых целей (ПРЦ).. Примерами таких задач могут служить следующие: распознавание надводных кораблей, распознавание нефтяных пятен, анализ морского волнения и ледовых образований, и т. п.

Входными данными для процессора служат радиолокационные изображения, импортированные во внутренний формат из одного из внешних форматов (CEOS, XML). Результатом обработки является растровое бинарное изображение с обнаруженными надводными кораблями (НК) и набор параметров, характеризующих НК (тип корабля, занимаемая площадь на поверхности, географическое положение



по широте и долготе). Полученное в результате обработки растровое бинарное изображение, представленное во внутреннем формате, может быть экспортировано в один из распространенных внешних форматов данных. Например, в графический формат GEO TIFF, который способен хранить географические координаты элементов изображения.

Процессор может работать как в автоматическом режиме, так и с участием оператора. Реализованный алгоритм имеет небольшое число параметров, варьирование которых позволяет повысить качество результата в случае сложных сцен.

Основные операции методики распознавания надводных кораблей по данным РСА заключаются в следующем.

Импорт данных и служебной информации (чтение файла данных, чтение параметров из формата CEOS, XML, формирование параметров для обработки.

Предварительная обработка (выделение интересующего участка).

Адаптивная пороговая классификация (подсчет статистик по изображению, формирование файла порогового значения, пороговая классификация).

Итеративная классификация (вычисление параметров статистических моделей классов, формирование массива «перспективных» пикселей формирование массива приращений функции энергии, оптимизация функции энергии и получение новой классификации).

Итеративная фильтрация (анализ геометрии бинарного изображения, фильтрация бинарного изображения).

Подсчет статистических характеристик работы классификатора.

Адаптивная пороговая классификация представляет собой пороговую классификацию с индивидуальным значением пороговой величины для каждого элемента изображения. Пороговая величина определяется по локальным статистическим характеристикам изображения. В результате проведения этого этапа обработки формируется начальная сортировка элементов изображения для последующей итеративной классификации.

Итеративный классификационный алгоритм оперирует не только в пространстве признаков, но и с исходным изображением. Это позволяет получить пространственно однородный результат классификации. Обработка проходит таким образом, чтобы оптимизировать некоторую функцию энергии на множестве возможных сортировок.

Итеративная фильтрация имеет своей целью повышение пространственной однородности результата классификации, и представляет собой нелинейную фильтрацию каскадом возрастающих по размеру окон.

Процессор распознавания кораблей (рис. В.1.) предназначен для выделения на фоне морской поверхности надводных судов, оценки их характеристик, таких, как: скорость и направление движения, размеры и координаты. Оценка скорости кораблей производится при наличии видимых на поверхности кильватерных следов.

Входными данными для процессора являются радиолокационные снимки морской поверхности в путевой системе координат в проекции наклонной или наземной дальности. Результатом обработки является векторный файл формата SHP с отметками обнаруженных кораблей и текстовый файл, содержащий перечень кораблей и оценки их параметров.



Рис. В.1. Обнаружение и распознавание кораблей

Поиск кораблей производится в автоматическом режиме с возможностью интерактивного редактирования оператором результатов поиска.

Оценка скорости производится по смещению судна относительно его кильватерного следа, выделенного в ручном режиме. Расчёт линейной скорости и направления движения производится процессором автоматически с использованием параметров КА, РСА и геометрии съёмки из состава служебной информации. Оценки размеров кораблей могут корректироваться в интерактивном режиме оператором.

Программа анализа морского волнения (рис. В.2.) предназначена для формирования оценок пространственного периода, направления распространения и высоты крупных энергонесущих волн на морской поверхности по радиолокационным снимкам.

В качестве первичного источника анализа программа формирует периодограмму морской поверхности с использованием БПФ и рассчитывает статистически устойчивые оценки спектра. Для уменьшения уровня боковых лепестков и повышения гладкости спектральных оценок используются весовые функции и пространственная фильтрация спектра.

По результатам анализа характеристик волнения программа способна построить карту пространственного распределения скоростей приводного ветра в предположении, что спектр волнения описывается распределением Пирсона – Мошковица.



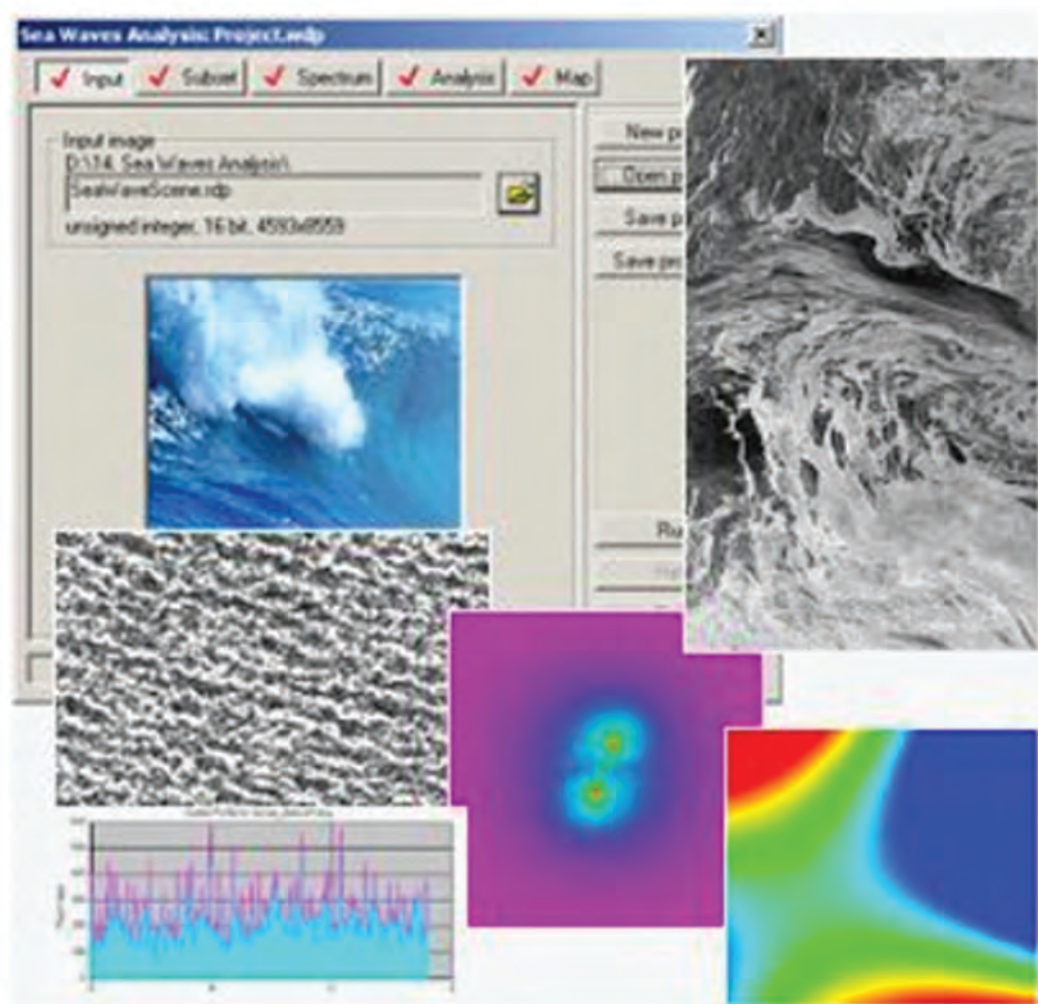


Рис. В.2. Программа анализа морского волнения

Результатом работы программы является набор растровых карт, характеризующих распределение пространственного периода и направления волнения, высоты волн и скорости ветра.

Программа способна работать как в автоматическом режиме, так и с участием оператора.

#### В.4. Литература к главе «Введение»

1. Воробьёва А.А. Дистанционное зондирование Земли. Учебно-методическое пособие. – СПб.: СПбУ ИТМО, 2012. – 168 с.
2. Грант Бенджамин. Вид сверху. Потрясающие снимки Земли со спутников = Benjamin Grant. Overview. М.: Альпина Паблишер, 2018. 284 с. – ISBN 978-5-9614-6615-7.
3. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА, формируемых в РСА монография – М.: Издательский дом Академии Естествознания, 2017.-212с.
4. Доросинский Л.Г., Трухин М.П. Приём и обработка сигналов от сложных целей: монография. – М.: Издательский дом Академии Естествознания, 2018. – 264 с.

---

## **1. РАСПОЗНАВАНИЕ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ (современное состояние проблемы)**

Радиолокационные изображения (РЛИ) Земли из космоса являются неотъемлемыми составляющими современного дистанционного зондирования Земли (ДЗЗ), в связи с отсутствием зависимости названных РЛИ от погодных условий и времени суток. Использование технологии синтеза апертуры (РСА) позволяет достичь сопоставимого с оптическим диапазоном пространственного разрешения, что дает возможность осуществлять наблюдение широкого круга объектов, начиная от лесных вырубок и заканчивая практически точечными целями, такими как транспортные средства или элементы антропогенных конструкций. Регулярно растущий круг задач, решаемых методами ДЗЗ, приводит к необходимости разработки алгоритмов, позволяющих выполнять автоматизированные работы по поиску и оценке изменений на местности в режиме реального времени.

В настоящее время принято различать две группы методов, позволяющих решать подобные задачи: обучение с учителем, основанное на использовании априорной информации о пространственно-распределенных целях (ПРЦ), и обучение без учителя, когда кластеризация изображений происходит в автоматическом режиме, основываясь исключительно на анализе наблюдаемых данных. Несмотря на то, что в области обработки оптических изображений за последние несколько десятилетий получены существенные результаты [1], проблема идентификации образов на радиолокационных изображениях остается актуальной. В отличие от изображений оптического диапазона формирование РЛИ выполняется при боковом обзоре, что существенно искажает образы целей и вызывает появление радиолокационных теней, причем обозначенные эффекты являются анизотропными, вследствие чего изображения одной и той же цели, полученные с разных ракурсов съемки, могут кардинально различаться [2, 3].

Наконец, неотъемлемой составляющей радиолокационных данных ДЗЗ является мультипликативный спекл-шум [4].

### **1.1. Формирование вспомогательных дешифровочных признаков**

Достаточно большое количество методов классификации РЛИ осуществляется параллельно либо после предварительного преобразования пространства изображения в обобщенную частотную область. Такой прием позволяет, во-первых, эффективно обнаруживать объекты заданной формы с учетом возможных аффинных преобразований по отношению к распознаваемому объекту, во-вторых, выявлять текстуру и/или форму отдельных областей космоснимков. При дальнейшей работе в новом пространстве возможно использование различных классификаторов с сохранением логики их первоначальных алгоритмов [5–9]. Существует большое количество методов преобразования изображений в различные типы частотных пространств, используемых в области обработки изображений, среди которых исторически первым методом является Фурье-преобразование.

---

#### **1.1.1. Фурье-преобразование**

Анализ частот в сформированной Фурье-области позволяет обнаруживать образы выраженной линейной формы, как, например, антропогенные и геологические объекты [10]. Также этот метод оказался эффективным в задаче обнаружения морских судов [7], благодаря стабильной составляющей спектра для высококогерентных участков изображения, что показано для данных всего используемого в ДЗЗ радиодиапазона. Отмечено, что обнаружение объектов в частотной области показывает хорошие результаты даже в условиях интенсивного спекл-шума [11]. Более общим случаем является дробное преобразование Фурье [12], позволяющее установить временное местоположение конкретных спектральных составляющих, что имеет большое значение при рассмотрении нестационарных процессов. Названный подход дополнительно позволяет снизить объем анализируемых данных за счет отбрасывания высокочастотных компонент [11].

#### **1.1.2. Преобразование Радона**

Близким по содержанию к Фурье-преобразованию является преобразование Радона [13], отображающее исходное изображение в новое пространство таким образом, что прямые линии преобразуются в точку. За счет этого становится возможным обнаруживать прямолинейные участки на РЛИ. В частности, преобразование Радона показало себя как эффективный инструмент поиска быстроходных морских судов за счет идентификации оставляемых ими следов на водной поверхности [14, 15]. Как и Фурье-преобразование, преобразование Радона позволяет получать надежные результаты даже в условиях очень целей, слабо отличающихся своим контрастом [16–18].

#### **1.1.3. Преобразование Хафа**

Дальнейшим развитием преобразований пространства изображения в частотную область является преобразование Хафа [19], позволяющее определить размер и ориентацию прямолинейных отрезков изображений, и обобщённое преобразование Хафа [20], дополняющее метод таким образом, что становится возможным осуществлять обнаружение кривых произвольной формы. Такой подход эффективно используется в задачах обнаружения дорог, границ сельскохозяйственных угодий, взлетно-посадочных полос и других тонких слабоконтрастных линий на РЛИ [21–23].

#### **1.1.4. Вейвлет-преобразование**

Более общим подходом при работе в частотной области является группа вейвлет-преобразований [24], в общем случае отображающих пространство изображения в пространство более высокой размерности, в котором две из осей связаны с частотной областью, остальные — с какими-либо анализируемыми признаками, например яркостью. Такой подход дополняет возможности Фурье-преобразования, позволяя через анализ вейвлет-коэффициентов учитывать различные локальные особенности сигнала, ассоциированные с особенностями отдельных образов на РЛИ [25]. Указанный подход нашел широкое применение в задачах распознавания областей, обладающих характерными текстурными особенностями [6-9], границ объектов различной формы [18], линейных объектов заданной формы и точечных целей [8]. В частности, применение метода вейвлет-преобразований дает хорошие результаты в задачах распознавания морских судов на водной поверхности и детектирования участков возгораний на разновременных данных ДЗЗ в различных диапазонах [26–28].

Помимо указанных выше методов отображения в частотную область, существуют их различные модификации, а также и иные типы преобразований, используемые при обработке РЛИ, преобразования Лапласа, Гильберта и Рисса [29–31], а также разложение изображения на полиномы Цернике [32–34]. За исключением Фурье-преобразования и полиномов Цернике, все эти методы объединяет идея выбора системы опорных функций таким образом, чтобы они максимально адекватно представляли текстурные, геометрические и иные свойства распознаваемых объектов. В ряде специфических задачах, например, при обнаружении заданных изменений на одновременных изображениях, зачастую, возможно использование преобразований в частотную область как самостоятельного инструмента классификации, однако наиболее широкое применение в проблеме распознавания образов на РЛИ они находят в сочетании с различными классификаторами. Однако следует отметить возрастающую вычислительную сложность алгоритмов, использующих дополнительные дешифровочные признаки, поэтому даже в случае применения сравнительно простых классификаторов возникает проблема оптимизации вычислительной процедуры.

## **1.2. Методы снижения размерности**

При распознавании и классификации РЛИ особенно остро встает проблема их размерности, поскольку современные радиолокационные системы ДЗЗ обеспечивают формирование изображений со строкой, содержащей, как правило, несколько тысяч элементов, а библиотеки признаков классов могут включать несколько десятков различных характеристик. Это приводит к так называемому «проклятию размерности», обусловленному требованиями исключительной мощности вычислительных ресурсов, при этом лишь незначительная часть обрабатываемых данных является принципиальной для обеспечения надлежащего качества распознавания [35]. С учетом этого бывает необходимо снизить размерность исходных данных в целях дальнейшей оптимизации процедуры их обработки за счет перевода изображения из пространства пикселей в пространство признаков, причем в большинстве случаев такая процедура помогает улучшить точность классификации. Одним из наиболее распространенных методов снижения размерности является метод главных компонент.

### **1.2.1. Метод главных компонент**

Суть метода главных компонент (Principal Component Analysis, PCA) заключается в представлении исходного массива данных в виде суммы компонент с коэффициентами, являющимися координатами векторов признаков в формируемом пространстве признаков. В качестве таких коэффициентов используются собственные значения ковариационной матрицы исходного изображения, за счет чего и достигается редукция размерности входного массива изображения с сохранением наиболее значимой информации. Применительно к задачам обработки РЛИ метод главных компонент используется в первую очередь как способ подавления спекл-шумов с целью последующей идентификации изменений на космических снимках, полученных в разное время и в разных условиях. Кроме того, метод PCA успешно применяется в сочетании с различными классификаторами, позволяя, с одной стороны, несколько ускорить процесс обработки, с другой стороны, увеличить точность распознавания [36–41].



### **1.2.2. Метод независимых компонент**

Из анализа метода главных компонент следует, что наилучшие результаты его использования будут достигаться в случае, если исходное распределение данных мало отличается от нормального. В общем случае распределение элементов вектор-строки РЛИ подчинено гамма-распределению, которое может быть аппроксимировано нормальным только в отдельных ситуациях. Поэтому следующим этапом развития метода главных компонент становится метод независимых компонент (Independent Component Analysis, ICA), предполагающий использование данных, подчиненных произвольному и в общем случае неизвестному распределению [42]. Для реализации этого преобразования используются оценки статистических моментов более высоких порядков и условия статистической независимости элементов вектора признаков, причем процедура расчета базисных векторов формируемого пространства зачастую связана со значительными вычислительными трудностями. Тем не менее, в сочетании с методом главных компонент для подавления спекл-шумов возможно распознавание морских судов с точностью более чем 95 % даже в условиях очень низкой контрастности целей [43], а использование различных классификаторов с учителем после применения метода независимых компонент демонстрирует точность распознавания не ниже 90 % на примере объектов базы MSTAR [44–45]. База MSTAR представляет собой серию РЛИ десяти различных транспортных средств военного назначения с пространственным разрешением 30 см и размером кадра 128×128 элементов, полученных в X-диапазоне при различных углах обзора. Это наиболее широко используемые тестовые изображения в работах, посвященных разработке и адаптации различных методов распознавания на РЛИ [46].

### **1.2.3. Низкоранговое матричное разложение**

Еще одним методом снижения размерности исходных данных является низкоранговое матричное разложение (Low-Rank Matrix Factorization, LMF). В методе предполагается, что любой вектор признаков может быть представлен в виде произведения двух совместимых матриц, по крайней мере один из размеров которых меньше, чем любой из размеров исходных данных [47]. Процедура разложения достигается за счет минимизации квадрата некоторой нормы от разницы исходного вектора и произведения искомых матриц. Применительно к задаче распознавания образов на РЛИ чаще всего используются две реализации низкорангового матричного разложения: NMF [48–49] и TSVD [3, 50–52].

## **1.3. Классификация без обучения**

Классификация без обучения, или сегментация, представляет собой декомпозицию изображения на некоторые множества, называемые кластерами, без использования какой-либо априорной информации о параметрах классов. Полученные в результате кластеры полностью охватывают исходное изображение, причем элементы каждого из кластеров обладают схожими характеристиками. Существует обширное количество разных подходов к процессу сегментации изображений, но применительно к РЛИ чаще всего используются следующие группы методов: пороговая обработка, кластеризация, алгоритмы с наращиванием областей, выделение границ, модели активного контура и марковские случайные поля.

### 1.3.1. Пороговая обработка

Пороговая обработка включает в себя простейшие алгоритмы сегментации и заключается в сопоставлении некоторого признака изображения с установленным заранее пороговым значением. Как правило, результат пороговой обработки представляет собой бинарное изображение, поэтому процедуру пороговой обработки иногда называют бинаризацией. В ряде случаев в качестве порогового значения может быть использована амплитуда либо некоторая функция от амплитуды РЛИ. Так, на данных ДЗЗ, обладающих различным типом поляризации, вертикально и горизонтально ориентированные объекты будут давать образы различной яркости, поэтому выбор в качестве порогового значения логарифма яркости для РЛИ дорог и мостов может быть успешно применен для сегментации изображения и дальнейшего распознавания таких объектов [53].

Существует три основных универсальных приема, лежащих в основе пороговой сегментации изображений РЛИ: анализ гистограммы изображения, расчет энтропии и метод Оцу (Otsu's method), заключающийся в анализе дисперсии изображения. В первой группе методов производится расчет и анализ различных параметров гистограммы, таких как высота и положение максимумов, степень асимметричности и кривизны, при этом роль исходного распределение элементов РЛИ, как правило, выступает гамма-распределение [54]. Порог устанавливается таким образом, чтобы минимизировать вероятность ошибочной классификации [54]. В отдельных случаях может быть использован порог Киттлера-Иллингворта [55]. Алгоритмы сегментации, основанные на анализе гистограмм изображений, демонстрируют высокую скорость обработки данных и в сочетании с методами предварительной пространственной адаптивной фильтрации [54, 56] дают эффективные результаты в задачах обнаружения изменений по данным [54, 57]. Приемы пороговой обработки могут быть расширены на различные производные признаки, такие как Фурье-пространство и вейвлеты. Так, анализ асимметрии энергии вейвлетов позволяет осуществить сегментацию не только исходя из яркостных признаков фрагментов РЛИ, но и текстурных [58].

При сегментации, основанной на расчете энтропии, пороговое значение устанавливается таким образом, чтобы энтропия всего изображения принимала максимально возможное значение. Изначально метод предполагал использование для расчетов информационной энтропии по Шеннону, однако применительно к изображениям, полученным с помощью технологии РСА, классическое выражение Шеннона было подвергнуто различным модификациям, например, использованием весовых коэффициентов при подсчете энтропии для смежных областей [59]. Надежные результаты в задачах классификации РЛИ могут быть достигнуты с использованием выражений для энтропии Реньи и перекрёстной энтропии, причем в обоих случаях выдвигается предположение об исходном гамма-распределении яркостей элементов РЛИ [60, 61]. Применение алгоритма KFCG, основанного на использовании элементов матрицы совместной встречаемости [62], позволяет разбить исходное РЛИ на большое количество непересекающихся классов с учетом их текстуры.

Выбор порогового значения в методе Оцу основан на максимизации межклассовой дисперсии. Применительно к РЛИ используется двумерный метод Оцу, в котором рассчитываются значения двумерной дисперсии вдоль двух направлений — собственно значений яркости отдельных элементов и значений усредненной яркости в рамках некоторого окна. Такой подход позволяет выполнять эффективную бинаризацию изображений даже в условиях достаточно интенсивного шума [63]. Сегментация

на основе двумерного метода Оцу показывает надежные результаты в задачах выделения объектов гидрографии [64] либо обнаружения различных образов на водной поверхности, например, следов разлива нефти [65]. В ряде случаев оказывается целесообразным производить расчет межклассовой дисперсии с учетом диагональных составляющих двумерного распределения в 2D-методе Оцу, что позволяет получить несколько более точные результаты [66].

### **1.3.2. Кластеризация**

Кластеризация основана на использовании алгоритма К-средних значений, общая идея которого заключается в минимизации разброса признаков элементов кластеров по отношению к их центрам масс, при этом оценка центров масс вычисляется итерационно до тех пор, пока происходит изменение расстояния между кластерами [67]. Число формируемых классов устанавливается заранее и, в отличие от пороговой обработки, может быть произвольным. Из-за присутствия спекл-шума применительно к РЛИ метод в своей классической форме малоэффективен, однако может давать хорошие результаты при расчете различных производных характеристик исходного изображения, например, усреднённого значения, дисперсии и энтропии [68], либо применительно к задаче детектирования изменений – разностного и среднего отношения. В целом такой подход обеспечивает достаточно точные результаты сегментации в сочетании с высокой скоростью обработки [69]. Кроме того, возможно комбинирование метода кластеризации с приемами пороговой обработки, например, с методом Оцу [70].

Метод нечеткой кластеризации (С-средних, Fuzzy C-means, FCM), по сути, представляет собой усовершенствованный метод К-средних, когда оценивается вероятность принадлежности элементов изображения к каждому из кластеров. Центры кластеров итерационно рассчитываются с использованием элементов матрицы принадлежности, алгоритм выполняется до тех пор, пока значение функции потерь не перестает уменьшаться [71]. При этом необходимо знать закон исходного распределения, в качестве которого может быть использовано гамма-распределение либо распределения Накагами-Релея [72]. В целом процедура сегментации обозначенным методом занимает больше времени, однако результат оказывается точнее в сравнении с классическим подходом кластеризации [72, 73]. Модификация нечеткой кластеризации, когда центры масс кластеров рассчитываются как среднегармонические значения, называется методом К-гармонических средних (K-Harmonic Means, КНМ) и показывает хорошие результаты сегментации для трех и более классов [74]. Еще одним вариантом модификации алгоритма К-средних является метод спектральной классификации (Spectral Classification, SC), основанный на применении собственных значений матрицы мер конвергенции, в качестве элементов которой используются оценки относительной схожести каждой пары точек исходного изображения. Сама идея метода SC основывается на теории графов, где проблема кластеризации рассматривается как проблема разделения графов. С этой точки зрения, данные, имеющие форму графа подобия, должны быть разделены на подграфы таким образом, чтобы ребра среди и между подграфами имели бы наименьший и наибольший веса соответственно [75]. В целом метод SC в сочетании с различными приемами, такими как формирование различных производных изображения и модификаций метрики [76, 77], показывает более точные результаты сегментации в сравнении с классическим алгоритмом К-средних [78], однако является вычислительно более громоздким и требует использования

различных математических допущений и приемов по снижению размерности анализируемого пространства, например, таких как низкоранговое матричное разложение [75–79]. Следует отметить, что при использовании кластерных методов в задаче сегментации РЛИ предварительная фильтрация, например, морфологическая обработка или фильтр Фроста, позволяют добиться более качественных результатов [69, 74].

### **1.3.3. Нарращивание областей**

Алгоритмы с наращиванием областей основаны на предположении, что соседние элементы одного кластера должны обладать схожими характеристиками на исходном изображении. На первом этапе вручную либо автоматически выбирается элемент изображения, называемый точкой посева, после чего происходит сравнение ее характеристик с ближайшими соседями в рамках некоторого окна, определяемого алгоритмом. В случае выполнения некоторого критерия схожести, который, как правило, представляет собой минимум разности между признаком точки посева и некоторой функции от анализируемого элемента, соседние пиксели присоединяются к точке посева, и выполняется рост региона (метод *Seeded Region Growing*, SRG). Способ выбора конкретного критерия схожести существенно предопределяет качество сегментации и должен быть выбран с учетом свойств исходного изображения. После завершения роста региона выбирается другая точка посева, не принадлежащая к сформированному ранее кластеру [80]. Методы, основанные на обозначенном подходе, являются довольно быстрыми с точки зрения машинного исполнения, поскольку вместо отдельных элементов изображения анализируют кластеры элементов [81, 82]. Помимо величины яркости, в рамках окна может быть произведен расчет других статистических характеристик, например, энтропии, что позволяет формировать кластеры с учетом текстуры изображения [83]. Сочетание алгоритмов наращивания областей с точками посева с другими методами сегментации, такими как SC и метод Оцу, обеспечивает точность классификации ППЦ выше, чем 90 % [80, 84]. На практике используется вариант разностного метода SRG, при котором сегментируется алгебраическая разность двух изображений одной и той же сцены, что может быть использовано в задачах обнаружения изменений, например, оценки последствий землетрясений [85].

Применительно к РЛИ хорошие результаты сегментации дает вариация метода с учетом статистических характеристик формируемых кластеров — статистическое слияние регионов (*Statistical Region Merging*, SRM). В обозначенном алгоритме первоначально каждый элемент изображения формирует отдельный самостоятельный кластер, при этом выполняется построение графа каждого из элементов с использованием четырех ближайших соседей. Далее осуществляется сортировка граничных элементов на основе статистических данных в случае, если параметры распределения объединенных участков не отличаются от двух формирующих, то объединенный участок сохраняется как отдельный кластер [86]. Сам критерий схожести статистики распределений объединенных кластеров обуславливается двумя параметрами, один из которых отвечает за интенсивность подавления спекл-шума, второй — за степень детализации выходных данных [87]. Метод SRM хорошо зарекомендовал себя при сегментации мультиполяризационных РЛИ различных диапазонов, при этом отмечается его слабая чувствительность к спекл-шумам и достаточно высокая скорость обработки [88]. Использование метода в качестве инструмента бинаризации РЛИ на примере распознавания аквакультур показывает результаты с точностью выше, чем 85 % [89].



#### **1.3.4. Выделение границ**

Границы кластеров тесно связаны с понятием перепадов яркости на изображении, откуда берет свое начало группа методов сегментации на основе выделения границ. Поиск границ основан на оценивании усредненных значений яркости в рамках некоторого окна и дальнейшем сравнении с пороговым значением, величина которого оценивается исходя из статистических свойств текущего фрагмента изображения [90]. Для формирования цельных участков на сегментированном изображении, наряду с классическими приемами по выделению границ на цифровом изображении применительно в задачах сегментации, должна быть решена проблема объединения полученных границ. Для решения этой задачи могут быть использованы морфологические фильтры [90] либо один из алгоритмов «водораздела» (watershed) [91, 92]. Процедура выполняется итерационно до тех пор, пока не будет достигнут минимум дисперсии по всем сформированным кластерам. В целом алгоритмы на основе выделения границ работают достаточно быстро и не требуют априорных сведений о статистических свойствах изображения, однако могут быть учтены посредством использования метода максимального правдоподобия для достижения более высокого качества сегментации РЛИ [92]. Они могут быть использованы в сочетании с другими методами сегментации, например, SRG, что позволяет получить низкую ошибку ложных срабатываний [90].

#### **1.3.5. Модель активного контура**

Метод модели активного контура (Active Contour Model, ACM) применяется в задачах обнаружения областей на изображениях. Здесь вводится понятие функционала энергии, описывающей свойства плоской кривой, параметрически заданной на изображении. Процедура сегментации сводится к минимизации функционала энергии, за счет чего происходит деформация активного контура таким образом, чтобы он оптимальным образом соответствовал границам кластеров [93]. Функционал энергии, как правило, определяется двумя составляющими: внутренняя энергия, определяемая количеством изгибов и степенью сжатия кривой, и внешняя энергия, отвечающая за смещение кривой к границам кластеров и определяемая через меру несхожести внешнего и внутреннего фрагментов изображения. В классическом методе ACM внешняя энергия рассчитывается как интеграл от результата перемножения некоторой функции активации с евклидовой метрикой, определенной на изображении, однако такой подход оказывается слишком чувствительным к спекл-шумам на РЛИ [94, 95]. Одним из способов модификации метода является замена классической метрики на логарифмическое отношение максимального правдоподобия [94–102], что позволяет существенно снизить влияние шумов на результат сегментации. При этом, как правило, выдвигается предположение о том, что яркость элементов РЛИ распределена в соответствии с гамма-распределением [94], [97, 98, 101, 103], однако возможно применение распределений Вейбулла [99] и Гаусса [100]. В качестве альтернативных способов изменения метрики при расчете внешней энергии может быть использована дивергенция Йенсена, такой подход обеспечивает низкую частоту ложных срабатываний и демонстрирует точность сегментации различных типов подстилающей поверхности вплоть до 100 % [104]. В качестве функции активации может быть использована радиальная базисная функция Гаусса [94, 105, 106] либо двумерная функция Хэвисайда [101, 103]. Сама процедура сегментации выполняется итерационно до тех пор, пока величина изменения функционала энергии не будет меньше

некоторого заданного порогового значения. В задачах уменьшения влияния шума на результат сегментации возможен также вариант использования аддитивного метода АСМ, в этом случае на каждой итерации осуществляется расчет нормализованных внутриклассовых значений дисперсии либо энтропии внешних и внутренних регионов изображения, полученные значения используются как аргументы весовых коэффициентов функционала энергии [105, 107].

Итоговая форма контура, описываемого полученным функционалом энергии, должна удовлетворять уравнению Эйлера-Лагранжа, которое решается с использованием численных методов, что в общем случае является достаточно трудоемкой и медленной процедурой [94]. Ускорение процедуры обработки возможно за счет минимизации функционала энергии через функцию градиента по каждому из параметров [99, 100, 105, 106], матричное разложение [97, 108], метод установки уровня, построение многоступенчатой модели на основе отдельных сжатых изображений [101]. Метод, основанный на модели активных контуров, показывает надежные результаты сегментации на примере модельных и реальных РЛИ, а также обнаружения объектов на водной поверхности, например, кораблей по данным различных диапазонов с точностью 90 % и выше [94, 95], нефтяных разливов [100, 107]. Построение функционала энергии с учетом дополнительных производных признаков изображения, таких как моменты изображений и вейвлет-преобразование, позволяет учесть текстуру изображения в ходе сегментации [108]. Предварительная пространственная фильтрация позволяет повысить точность сегментации [102, 108].

### **1.3.6. Скрытые марковские поля**

Использование идеи марковских случайных полей (Random Markov Field, RMF) относится к области полуавтоматизированных методов классификации изображений, находящихся на промежуточной стадии между сегментацией и обучения с учителем. Наиболее естественным способом определения марковских случайных полей применительно к задаче сегментации изображений является представление последнего в виде неориентированного графа, причем в качестве вершин графа выступают элементы изображения, а ребра графа представляют собой связи элементов между собой. Процедура сегментации в данном случае отождествляется с разделением графа на подграфы в соответствии с некоторыми признаками, при этом в основе лежит, как правило, использование байесовского подхода [109]. Апостериорная вероятность будет определяться функцией правдоподобия, определяемой исходными данными, и априорной вероятностью, учитывающей ближайшее окружение элемента. Наилучшему результату разбиения графа будет соответствовать максимум апостериорной вероятности, либо, в соответствии с теоремой Хаммерсли-Клиффорда [110], минимум потенциальных функций распределения Гиббса, что позволяет перейти от апостериорной вероятности к апостериорной функции энергии графа, определяемой через два и более слагаемых. Количество слагаемых соответствует количеству элементов ближайшего окружения анализируемого пикселя РЛИ. Как правило, при использовании метода RMF ограничиваются четырьмя ближайшими соседями, что соответствует двум слагаемым в выражении для функции энергии [111], однако при анализе текстуры бывает удобно использовать девять ближайших соседей и более [112, 113], Модифицированный алгоритм RMF позволяет использовать количество элементов окружения в роли адаптивного параметра [109]. Применительно к РЛИ сегментация с применением марковских случайных полей обладает рядом преимуществ,

поскольку не требует предварительного подавления [111] спекл-шумов и в сочетании с вейвлет-преобразованиями может быть использована для учета текстуры отдельных фрагментов изображения [114, 115]. Следует отметить, что сегментация на основе марковских случайных полей является достаточно трудоемким методом, и для ускорения процедуры обработки по нахождению минимума функции энергии, как правило, используются различные дополнительные приемы, например, метод градиентного спуска [111]. В целях оптимизации возможно выполнение сегментации в несколько этапов, соответствующих разной степени детальности для выражения функции энергии [112, 114]. Хороший результат по скорости получения результата может быть достигнут при использовании предварительной классификации без учителя, например, алгоритмом водораздела [116] либо наращиванием областей методом SRG [81, 117].

Несмотря на высокие требования к вычислительной технике, метод RMF показывает высокие результаты классификации, превосходя по точности традиционные методы обучения без учителя [111]. Формируемые атрибутивные данные обладают высокой степенью однородности [109, 116], а для метода в целом характерно низкое значение ошибок пропуска и ложных срабатываний [112, 115]. Применение марковских случайных полей особенно эффективно при анализе текстур изображения [112, 115] и позволяет корректно сегментировать даже сравнительно тонкие детали схожих по яркостным признакам фрагментов РЛИ [114, 118]. В частности, показано успешное применение метода RMF на примере данных различных диапазонов в задаче классификации пяти и более типов подстилающей поверхности с точностью не хуже 90 %. Также марковские случайные поля могут быть использованы при обработке мультиполяризационных данных, при этом связь между отдельными каналами многомерного изображения задается через корреляционные матрицы [81, 109].

### **1.3.7. Вывод по разделу 1.3**

В большинстве случаев результаты классификации РЛИ без учителя оказываются менее точными в сравнении с алгоритмами, основанными на обучении. Достаточно надежные результаты могут быть получены только для кластеризации регионов с сильно различающейся эффективной поверхностью рассеивания, как, например, в задачах выделения гидрографических объектов на общем фоне изображения либо обнаружения различных целей на водной поверхности. В случае, когда яркостные свойства классифицируемых регионов слабо различаются, надежные результаты могут быть получены преимущественно для модельных изображений, в случае применения предлагаемых алгоритмов к реальным РЛИ значительная доля успешных испытаний соотносится скорее с удачным выбором набора пороговых значений и различных параметров применяемых моделей сегментации, который не будет универсальным как для различных РСА-систем, так и для различных сцен, формируемых одной РСА-системой. Как правило, в реальных практических задачах полученные в ходе сегментации данные используются в качестве предварительной оценки структуры изображения с целью выбора дальнейшего метода классификации либо обнаружения уже с применением учителя. Тем не менее, сегментированные изображения в ряде случаев могут дополнять методики, основанные на обучении, например, метод опорных векторов [119]. Так, результат сегментации РЛИ кластерным методом SRM в сочетании с методом опорных векторов показывает возможность классификации различных типов растительности (более 10 классов) с точностью не хуже, чем 90 % [120, 121], а дополнительный расчет коэффициентов вейвлет-преобразования позволяет проводить

кластеризацию с учетом не только яркостных, но и текстурных признаков [6]. Однако следует отметить, что формируемые в ходе алгоритмов без обучения области оказываются достаточно неоднородными и в большинстве случаев требуют применения морфологических фильтров и иных приемов улучшения РЛИ перед применением в качестве самостоятельной карты признаков. Также следует отметить затруднительную процедуру оценки точности методов сегментации РЛИ, в большинстве случаев оценка точности производится постфактум, визуально исходя из границ контуров реальных объектов.

#### **1.4. Классические методы**

Классические методы классификации изображений включают в себя группу параметрических алгоритмов с обучением, в основе которых лежит максимизация апостериорной вероятности принадлежности элементов изображения к конкретному классу либо минимизация рисков попадания в некорректные классы. Сами алгоритмы при условии, что плотности вероятностей распределений классов известны, в этом случае могут быть представлены в явном аналитическом виде, и, более того, представленные алгоритмы оказываются оптимальными [122], то есть вероятность ошибок будет наименьшей из возможных. Применительно к задачам обнаружения целей на РЛИ в качестве плотностей распределения вероятностей, как правило, используется гамма-распределение, конкретные его параметры могут быть оценены на основе элементов обучающей выборки, однако в этом случае алгоритмы теряют свойство оптимальности, поскольку восстановление параметров возможно только с некоторой погрешностью. Приведенная группа методов представляет собой наиболее ранние алгоритмы классификации и распознавания изображений, однако до настоящего времени не теряют своей актуальности как в классической форме, так и в составе различных гибридных решений. Применительно к радиолокационным данным ДЗЗ чаще всего из этой категории алгоритмов применяется байесовский классификатор, линейный дискриминантный анализ и логистическая регрессия, а также во многих схожий в контексте формализации алгоритм постоянной вероятности ложных тревог.

##### **1.4.1. Байесовский классификатор**

Классический подход распознавания образов на изображении основан на непосредственном использовании байесовского классификатора [122], в основе которого лежит прямое использование теоремы Байеса и описание вероятностей распределения исходных данных. В задаче распознавания ПРЦ на РЛИ в качестве априорного закона распределения яркостей элементов чаще всего используется гамма-распределение [123–126]. Однако в ряде случаев, например, в случае предварительной пространственной фильтрации изображения [123], вероятностный закон для яркостей элементов изображения может быть заменен на нормальный, что позволяет несколько ускорить расчеты, сохраняя точность получаемых результатов [123, 127, 128]. Для уточнения априорного распределения вероятностей дополнительно может использоваться какой-либо из методов оценки меры схожести теоретического распределения и гистограммы РЛИ, например, расчет дивергенции [124]. В качестве метода оценки параметров байесовских моделей, как правило, применяется метод максимального правдоподобия [124, 126, 127], однако правомерными оказываются и иные подходы, например, минимизация дивергенции Кульбака-Лейблера [129, 130].

Полученная оценка позволяет минимизировать апостериорный риск по интересующему набору параметров неопределенности, что позволяет в конечном счете не только установить наличие либо отсутствие образа цели на РЛИ, но и выполнять оценку значений ее координат, геометрических параметров и величины эффективной поверхности рассеивания [123, 131].

Алгоритм байесовского классификатора показывает высокую эффективность в задачах обнаружения различных целей по радиолокационным данным ДЗЗ. Названный подход демонстрирует точность выше 90 % в задачах обнаружения морских судов трех различных типов на водной поверхности по данным RADARSAT-2 [130] и объектов базы MSTAR [132]. Также байесовский классификатор успешно применяется в задаче обнаружения изменений по разновременным изображениям, в этом случае на предварительном этапе выполняется привязка и строится вспомогательная матрица, представляющая собой отношение исходных РЛИ. В этом случае плотность вероятности оказывается симметричной относительно отношения математических ожиданий исходных данных, что облегчает последующее применение теоремы Байеса [124].

Расширением реализации классического байесовского классификатора является Байесовская сеть (Bayesian network) – вероятностная графовая модель, состоящая из множества трех и более признаков и их вероятностных зависимостей, определяемых по теореме Байеса. Такой подход используется в задачах идентификации различных типов целей (от четырех и более) при анализе значительной совокупности признаков, включая текстурные, причем байесовская сеть позволяет не только оценить местоположение и характеристики цели, но и угол ее наблюдения [128, 133]. Следует отметить, что обозначенный алгоритм оказывается вычислительно ёмким, поэтому в качестве априорного распределения яркостей элементов изображения, как правило, используется нормальное распределение, а для оптимизации расчетной процедуры могут оказаться эффективными различные вспомогательные методы, например, Венгерский алгоритм [127]. Использование байесовской сети в качестве классификатора в задачах обнаружения образов целей на РЛИ позволяет достигнуть точности до 99 % на примере обнаружения объектов базы MSTAR [127].

Классический подход к распознаванию образов на РЛИ, основанный на теореме Байеса, может успешно сочетаться с различными приемами по снижению размерности. Особенно эффективно в этом плане проявляет себя низкоранговое матричное разложение, при использовании которого точность распознавания отдельных типов объектов базы MSTAR достигает 99 % [134], которое так же может использоваться как инструмент снижения размерности в задаче обнаружения изменений по полным сценам космоснимков [135]. Также широкое применение находит предварительное преобразование с помощью метода главных компонент [136–138] и выделение частотных признаков с использованием вейвлет-преобразования, позволяющее достигнуть точности распознавания до 95 % и выше на примере реальных радиолокационных данных ДЗЗ [8, 9, 139]. Достаточно часто встречаются различные гибридные архитектуры, например, использование принципов байесовской классификации на этапе нахождения оптимальных «атомов» в методе разреженных представлений [140–142], демонстрируя точность, превышающую 97 % на примере распознавания объектов базы MSTAR. Байесовский классификатор успешно применяется на этапе обучения свёрточных нейронных сетей, позволяя достигнуть точности распознавания целей по реальным РЛИ до 98 % и выше без значительного углубления сети [125, 143, 144].



#### **1.4.2. Дискриминантный анализ**

Метод линейного дискриминантного анализа (Linear Discriminant Analysis, LDA) представляет собой алгоритм, принципиально не отличающийся от метода главных компонент. Построение пространства признаков выполняется в виде линейной комбинации исходных данных, причем направление новой оси подбирается таким образом, чтобы максимизировать разделимость между классами в соответствии с эталонными выборками [122]. Для нахождения коэффициентов перехода к новому пространству признаков чаще всего используется критерий Фишера, основанный на расчете матриц разброса внутри класса и между классами. Множественный дискриминантный анализ (Multiple Discriminant Analysis, MDA) представляет собой естественное обобщение линейного дискриминантного анализа, в этом случае пересчет происходит не на одну, а сразу на несколько новых координатных осей с учетом вышесказанных критериев. Зачастую для нахождения координат в новом пространстве признаков изображения эталонной выборки требуют существенной предварительной обработки [145], например, эквализация гистограмм, использование сглаживающих пространственных фильтров, а также предварительный перевод в частотную область с целью устранения сдвиговых эффектов образов [146]. Применительно к задачам распознавания образов на РЛИ линейный и множественный дискриминантный анализ не применяются, однако могут быть успешно интегрированы с иными методами классификации с обучением, например, метод опорных векторов [145–147] и искусственные нейронные сети [148, 149].

#### **1.4.3. Логистическая регрессия**

Метод классификации, основанный на использовании логистической регрессии (Logistic Regression, LR), подобно байесовскому классификатору, основан на прогнозировании вероятности отнесения вектора признаков к тому или иному классу с помощью сравнения с логистической функцией, отклик которой принимает бинарные значения, что соответствует наличию либо отсутствию образа цели на изображении [150]. Конкретные значения коэффициентов регрессии определяются по параметрам обучающей выборки, для их последующей оценки, как правило, применяется метод максимального правдоподобия, градиентного спуска либо пошагового отбора [151, 152]. Метод может быть расширен на решение задачи о поиске целей различных типов (множественная логистическая регрессия (MLR)), в этом случае отклик логистической функции может принимать три и более значений. В частности, в задачах классификации мультиполяризационных данных ДЗЗ на восемь классов использованием метода MLR может быть достигнута точность до 90 % в сочетании с низкими значениями ошибок ложного срабатывания [151]. Следует отметить, что в исходной форме метод логистической регрессии в задачах обнаружения целей на РЛИ используется достаточно редко, однако сравнительно часто применяется на последнем слое архитектуры искусственных нейронных сетей в качестве классификатора [40, 41, 153–157].

#### **1.4.4. Постоянная вероятность ложных тревог**

Постоянная вероятность ложных тревог (Constant false alarm rate, CFAR) представляет собой адаптивный алгоритм, применяемый в сфере радиолокации в задачах обнаружения цели при условии присутствия существенного шума. Принятый радиолокатором отраженный сигнал включает в себя как полезную составляющую, так

и различные помехи, обусловленные как собственным шумом приемника, так и всевозможными внешними факторами. Алгоритм CFAR предназначен для оценки минимального порогового значения мощности, при превышении которого сигнал следует считать относящимся к цели. При чрезмерно низком значении порога будет увеличиваться число ошибок ложного срабатывания, при высоком, напротив, количество ошибок ложного срабатывания будет сведено к минимуму, однако возрастет число ошибок пропуска. В большинстве задач обнаружения полезного радиолокационного сигнала при проектировании РЛС величина порогового значения устанавливается исходя из требований к вероятности возникновения ошибок ложных тревог. В подавляющем большинстве реальных ситуаций уровень шума не является постоянной величиной и является функцией пространственных и, в ряде случаев, временных координат, в этом случае пороговое значение должно изменяться по ходу выполнения алгоритма поиска цели для поддержания постоянной ошибки ложных тревог [158]. Применительно к задачам обработки РЛИ в этом смысле формализация алгоритма CFAR подобна классическому подходу, поскольку расчет величины необходимого порога осуществляется исходя из анализа статистических свойств радиолокационных изображений и последующего применения аппарата теории вероятности.

В случае использования алгоритма CFAR по отношению к двумерному сигналу его классическая форма требует ряда модификаций, для решения этой задачи используется два подхода. Первый подход, как правило, основан на предварительном выделении границ участков изображения, в качестве метода может быть использован оператор Собеля [159–161], расчет градиента вдоль направлений азимута и дальности [162], различные методы предварительной сегментации [163]. Этот этап позволяет выделить потенциальные области, соответствующие положению образа цели и упростить дальнейшие вычисления, однако может быть заменен на разбиение исходного изображения на некоторое количество фрагментов и последующего расчета в рамках каждого из них [164]. На следующем этапе на границах полученных регионов находится условная плотность вероятности для двух окрестностей, расположенных по разные стороны, и с ее помощью находится оценка порогового значения [159]. За исходное распределение яркостей элементов РЛИ в этом случае берется либо гамма-распределение [159, 160], либо некое его обобщенное представление, например,  $G_0$  [165] или GGD [164, 166]. Для оценки параметров используемых распределений дополнительно могут применяться различные методы, например, метод Парзенковского окна [161] или метод логарифмических кумулянт [164]. Далее задается величина вероятности ошибки ложного срабатывания, как правило, несколько сотых долей процента [159, 162, 165], и на основе этого значения выполняется расчет величин порогового значения [159]. На заключительном этапе с целью упрощения анализа результатов может применяться морфологическая фильтрация [159, 160, 163], кластеризация [165] и медианная фильтрация [160]. Полученный алгоритм показывает высокую эффективность в задачах обнаружения различных целей, таких как объекты базы MSTAR [160, 165] и обнаружение морских судов на водной поверхности [161, 162] даже на детальных РЛИ, показывая добротность (отношение общего числа корректно найденных целей к сумме ложных срабатываний и действительному количеству целей), приближающуюся к 100 % при ошибке ложного срабатывания, составляющей 0,01 % [160]. Показано, что с ростом размера областей, в рамках которых происходит подсчет статистики РЛИ, увеличивается оценка порогового значения [159], поэтому алгоритм может быть использован даже для нахождения слабоконтрастных целей.

Второй подход адаптации к двумерным сигналам основан на применении двухпараметрического метода CFAR, основанного на расчете двух статистических параметров в рамках двух концентрических окон элемента изображения, причем размер малого окна соотносится с характерным размером образа цели. Первый параметр представляет собой нормализованное значение яркости элемента, а второй параметр — разность либо отношение дисперсий элементов в пределах концентрических окон [167–169]. В этом случае работа алгоритма основывается на том факте, что значение яркости элементов цели превышает значения элементов яркости окружающих элементов. После получения оценок, как правило, применяется показатель степени Хёрста [170], позволяющий осуществлять поиск образов целей по всей области изображения как единого целого [167, 169]. Задание необходимого уровня вероятности возникновения ошибок ложного срабатывания осуществляется через формирование кривой ошибок. На завершающем этапе для устранения разрывов и упрощения последующей интерпретации результата может применяться обработка морфологическим фильтром [169]. Приведенная схема алгоритма CFAR позволяет выполнять поиск целей на изображении с точностью до 95 % и выше, что показано на примере объектов базы MSTAR [167, 169], а также осуществлять предварительный анализ точности алгоритма. Следует отметить, что в такой реализации алгоритма CFAR предложение об исходном распределении значений яркости элементов изображения задается как нормальное, поскольку распределения более сложной формы требуют существенного увеличения времени обработки.

#### **1.4.5. Вывод по разделу 1.4**

Несмотря на сравнительно простую формализацию, байесовские классификаторы и иные методы классификации, основанные на минимизации апостериорных рисков, в ряде случаев могут обучаться достаточно эффективно и зачастую по точности получаемых результатов могут составить конкуренцию различным методам глубокого обучения, таким как искусственные нейронные сети. Классические подходы распознавания по радиолокационным данным ДЗЗ, являются в значительной мере робастными, что особенно актуально по отношению к РЛИ, неотъемлемым свойством которого является присутствие мультипликативного спекл-шума. Большинство работ, основанных на использовании этой группы методов, содержит разделы, посвященные дополнительным исследованиям их точности при вариации параметров целей и шумов, что позволяет делать выводы об оценке алгоритмов распознавания без длительной их апробации, а также целесообразности их применения в различных ситуациях. Приведенные методы не требуют значительных вычислительных ресурсов и в большинстве случаев дополнительных процедур оптимизации расчетов, что позволяет решать задачу поиска целей на РЛИ достаточно быстро. Однако в настоящий момент в научном сообществе представлено сравнительно немного работ, основанных на использовании исключительно классических подходов, за исключением алгоритма CFAR, что позволяет сделать вывод о недостаточной тщательности проведенных исследований по возможности их применения, а также потенциальных перспективах использования.

#### **1.5. Классификация с обучением**

В основе методов классификации изображений с учителем лежит использование обучающих выборок — наборов эталонных фрагментов, относительно которых достоверно известен тип определяемого класса. Процедура распознавания заключается



в сопоставлении признаков (яркостных, текстурных, геометрических и иных) анализируемых элементов изображения и эталонов, а решение принимается в пользу того класса, для которого мера схожести является наибольшей. Наиболее простой непараметрической реализацией классификации с обучением является использование взаимной корреляционной функции.

#### **1.5.1. Взаимная корреляционная функция**

Несмотря на то, что в области ДЗЗ взаимная корреляционная функция (cross-correlation) широко используется в задачах автоматизированной геопривязки космоснимков [171–175], в ряде случаев она может выступать как один из простейших методов обнаружения цели заданного вида на РЛИ. Если на анализируемом изображении присутствует фрагмент, подобный эталону, отклик взаимной корреляционной функции будет содержать характерный максимум, который будет зависеть от степени сходства фрагмента с эталонным изображением [176]. Таким образом, в задачах поиска ПРЦ на РЛИ необходимо произвести расчет взаимной корреляционной функции для всех возможных эталонов, при этом истинному типу цели будет соответствовать эталон того класса, для которого максимум взаимной корреляционной функции окажется наибольшим.

Как следует из описания, использование взаимной корреляционной функции как метода распознавания образов возможен только для обнаружения объектов заданной формы и размера. В случае, если эти параметры заранее неизвестны (например, задачи классификации РЛИ, либо обнаружение вырубок и застроенных территорий) отклик корреляционной функции не даст выраженного максимума. При использовании корреляционного метода вероятность правильного распознавания типа целей прямо пропорциональна ее размеру, таким образом, метод является пригодным только в том случае, если эталоны для различных типов целей могут быть формализованы помимо яркостных характеристик с использованием иных, не связанных с пространственными размерами, параметров, например, структуры или текстуры изображений [177]. Для метода характерна существенная вычислительная сложность, растущая пропорционально квадрату исходного РЛИ [178]. Тем не менее, в задачах распознавания образов на радиолокационных данных ДЗЗ метод, основанный на использовании взаимной корреляционной функции, обладает рядом преимуществ, в частности, он практически не чувствителен к отношению сигнал-шум и позволяет детектировать сравнительно низкоконтрастные объекты [179], кроме того, в ряде работ отмечается достаточно низкая частота ложных срабатываний обозначенного метода [178, 179], а сочетание с приемами по переходу в пространство признаков с использованием метода независимых компонент позволяет достигнуть точности распознавания до 90 % и выше [45].

#### **1.5.2. Расстояние Махаланобиса**

Традиционные подходы к процедуре классификации с обучением ассоциированы с непосредственным переходом в пространство признаков, и решение для каждой из ПРЦ принимается в пользу того класса, для которого некоторая мера между вектором наблюдаемых данных и положением усредненных характеристик эталона в пространстве признаков принимает наименьшее значение. Существует большое количество способов выбора метрик для оценки этой меры [180]. Одним из примеров такой метрики является расстояние Махаланобиса [181], представляющее собой обобщающее понятие евклидовой метрики, в котором осуществляется учет корреляций между случайными величинами.

Метод, основанный на расчете расстояния Махаланобиса, показывает достоверные результаты с точностью до 90 % при обнаружении изменений на местности произвольных геометрической форм и размеров в таких задачах, как оценка последствий землетрясений и разлива нефти на морской поверхности на примере фрагментов космоснимков, полученных с применением технологии РСА в различных диапазонах [182, 183]. Отмечается низкое значение ошибок ложного срабатывания и пропусков целей, кроме того, метод успешно применяется в задачах классификации различных типов подстилающих поверхностей, обладающих схожими характеристиками, например, в задаче классификации ледовой поверхности [184], причем расчетные процедуры выполняются сравнительно быстро и не требуют специальных решений по оптимизации вычислений [182].

### **1.5.3. Метод $k$ -ближайших соседей**

В методе  $k$ -ближайших соседей ( $k$ -Nearest Neighbors,  $kNN$ ) объекту присваивается тот класс, который является наиболее распространенным среди  $k$  соседей данного элемента, классы которых уже известны на основе обучающей выборки [185]. Выбор конкретного значения параметра  $k$  является самостоятельной процедурой, требующей отдельных исследований, поскольку его занижение может привести к росту ошибок пропуска, а чрезмерное его увеличение снижает четкость разделения между границами классов. Как правило, в методе  $kNN$  используется нормализация различного типа, например, минимакс-нормализация или  $Z$ -нормализация, что позволяет избежать зависимости от различий в ширине диапазонов атрибутивных признаков. Метод является непараметрическим, что подразумевает отказ от прямого рассмотрения статистических свойств анализируемого РЛИ. Метод  $k$ -ближайших соседей является примером одного из наиболее простых классификаторов с учителем как в плане технической реализации, так и с точки зрения потребляемых временных ресурсов, тем не менее, он показывает результаты распознавания, как правило, с точностью не хуже, чем 90 % на примере задачи обнаружения объектов базы MSTAR [30, 186, 187].

### **1.5.4. Метод опорных векторов**

В задачах распознавания образов практика перехода из пространства элементов в пространство признаков оказывается полностью оправданной, однако для классификации образов, обладающих схожими характеристиками, бывает целесообразно искусственно увеличить размерность пространства признаков таким образом, чтобы стало возможным адекватно разделить схожие классы, т.е. провести разделяющую их гиперплоскость. Эта идея лежит в основе метода опорных векторов (Support Vector Machines, SVM) [188], в котором увеличение размерности пространства признаков осуществляется с помощью специального преобразования, определяемого функцией ядра классификатора. Существует множество распространенных вариантов для выбора функции ядра, например, радиальная базисная функция Гаусса [140, 189, 190], полиномиальная [36, 190], линейная [190] и другие. Первоначально метод предполагал формирование линейных разделяющих гиперплоскостей, однако позже появились его различные обобщения в виде нелинейных гиперплоскостей [191] и метода релевантных векторов [192, 193], позволяющие более эффективно выполнять оценку вероятности принадлежности элемента к тому или иному классу. После построения серии оптимальных разделяющих гиперплоскостей в соответствии с эталонной выборкой элементы РЛИ могут быть успешно соотнесены со «своими» классами.

Метод опорных векторов позволяет достигнуть точности 90 % и выше в задачах распознавания объектов базы MSTAR [36, 37, 190, 194] в сочетании со сравнительно низким уровнем ошибок пропуска цели [36, 39, 134, 140, 190, 195]. Метод опорных векторов успешно используется в сочетании с различными приемами преобразованию пространства признаков, такими как метод главных компонент [36, 37] и метод независимых компонент [44], неотрицательного матричного разложения векторов признаков обучающей выборки (NMF) [134], а также выделению дополнительных дешифровочных признаков с помощью Фурье-преобразования [194] и нахождения центральных моментов изображения [119, 190].

Наиболее точные результаты достигнуты с применением гибридной технологии с применением классических подходов, таких как байесовский классификатор [134, 140, 145, 146, 195] и дискриминантный анализ [147], причем данный подход является в ряде случаев единственным возможным решением и зачастую показывает результаты более точные, чем использование искусственных нейронных сетей [36, 189, 193]. Однако метод обладает достаточно низкой скоростью обучения, кроме того, существуют повышенные требования к вычислительным ресурсам при использовании большого количества признаков, особенно в случае нелинейной гиперплоскости. Некоторого ускорения расчетной процедуры можно достичь, используя низкоранговое матричное разложение [48, 49, 51]. Точность классификации РЛИ возрастает обратно пропорционально количеству распознаваемых классов [39, 194], поэтому использование метода SVM не является универсальным решением. Отдельно следует отметить необходимость предварительного анализа исходных данных, необходимых для грамотного выбора адекватных параметров ядра классификатора [39, 193], что полностью предопределяет результаты работы алгоритма.

#### **1.5.5. Метод разреженных представлений**

Для снижения размерности исходных данных используется метод разреженного представления (Sparse Representation, SR), в котором произвольный вектор признаков представляется в виде взвешенной суммы векторов признаков эталонной выборки («словарь»), большинство компонент которых будут иметь нулевой либо почти нулевой коэффициент, за счет чего и достигается эффект разреженности. В качестве таких ненулевых компонент («атомов») могут выступать границы объектов, текстурные особенности и иные признаки, значительно отличающиеся друг от друга. Сам эффект разрежения размерности достигается за счет минимизации внутриклассового разброса по квадрату некоторой нормы, причем полученные таким способом «атомы» будут идеально соотноситься с образцами, относящимися к тому же классу, по эталону которого выполнена минимизация. Сама процедура минимизации является NP-жесткой, и зачастую ее решение требует значительных самостоятельных исследований [3, 29, 196]. Существуют разные методы решения задачи минимизации, в качестве примера можно привести метод случайной проекции [196, 197] либо метод согласованного преследования [198, 199].

Метод разреженных представлений на примере обнаружения объектов базы MSTAR демонстрирует точность распознавания, превышающую 90 % [200], в сочетании со сравнительно высокой скоростью обработки, причем в ряде случаев оказываясь точнее, чем иные методы классификации с учителем, например, метод опорных векторов [11, 196] и метод k ближайших соседей [30, 186, 201]. Как и для метода SVM, точность классификации растет с уменьшением количества распознаваемых

классов [200]. Особую эффективность метод разреженных представлений демонстрирует в сочетании с другими приемами, такими как предварительный перевод изображения в частотную область [11] и снижение размерности пространства признаков с использованием низкорангового матричного разложения [50]. Метод успешно применяется в задаче многопоточной классификации для обработки серии РЛИ с различным пространственным разрешением [202, 203].

#### **1.5.6. Дерево решений**

Еще один способ классификации изображений с учителем основан на поэтапном разбиении пространства признаков на непересекающиеся области. Такой подход называется деревом решений, при этом каждому узлу дерева соответствует определенный атрибут, в зависимости от значения которого и происходит этап классификации [204]. Применительно в задачах распознавания образов по РЛИ чаще используется метод под названием «случайный лес» (Random Forest, RF), основанный на использовании большого ансамбля деревьев решений. В этом методе генерируется случайная дополнительная выборка из обучающих векторов, для которых строится решающее дерево, причем для создания очередного узла выбирается некоторое количество случайно однообразных признаков. Критерий выбора наилучших из признаков может быть различным, например, критерий Джини или критерий прироста информации. Решающее дерево строится до полного исчерпания дополнительной выборки и, в отличие от классического дерева решений, не подлежит процедуре отсечения ветвей. Сам процесс классификации проводится путем голосования, при этом побеждает тот класс, за который проголосовало наибольшее число решающих деревьев [205].

Метод «случайный лес» показывает высокую эффективность в задачах классификации полного кадра РЛИ на примере данных различных диапазонов, в особенности при использовании мультиполяризационных данных [38, 206, 210]. Точность классификации при этом составляет 70 % и выше для различных типов агрокультур и 90 % и выше для антропогенных объектов [206, 207, 209, 211].

В общем случае отмечаются высокая эффективность метода «случайный лес» в задачах классификации данных с большим количеством признаков, при этом возможна достоверная классификация в случае присутствия в кадре десяти и более различных классов [209, 211]. Однако метод требует достаточно большого объема памяти для хранения формируемых моделей, и как, следствие, обладает низкой вычислительной мощностью [34, 38]. Широко применяется гибридная технология «вращение леса», основанная на сочетании метода RF с методом главных компонент, что позволяет, с одной стороны, снизить размерность исходных данных и ускорить процесс обработки, с другой стороны, несколько повысить точность классификации [38, 212].

#### **1.5.7. Модель ASC**

Несколько обособленное положение в распознавании образов по радиолокационным данным ДЗЗ занимает подход, основанный на предварительном моделировании двумерных образов распознаваемых целей с учетом всех параметров съемки, а также геометрических и яркостных свойств конкретного типа (модель Attribute Scattering Centre, ASC) [3]. Полученные модели выполняют роль элементов обучающей выборки, в дальнейшем выполняется их сопоставление с реальными фрагментами РЛИ тем или иным методом. В качестве классификатора могут быть использованы классические

методы распознавания, такие как байесовский подход [213, 214], метод опорных векторов [213, 215] и разреженных представлений [213, 215–217]. Для поиска соответствий моделей ASC с фрагментами РЛИ возможно использование менее традиционных приемов, например, применение венгерского алгоритма за счет матричной интерпретации исходных данных [218, 219]. Применение моделей ASC в ряде случаев демонстрирует более точные результаты по сравнению с искусственными нейронными сетями [215]. Алгоритмы распознавания целей, основанные на применении моделей ASC, показывают точность классификации выше, чем 95 %, на примере задач обнаружения объектов базы MSTAR [215, 216, 219] при слабой чувствительности метода к пространственному разрешению итоговой модели [219] и возможности обработки мультиполяризационных данных [214]. Однако следует отметить, что такой способ классификации изображений достаточно трудоемкий, поскольку требует, как полной априорной информации о свойствах распознаваемых классов и параметров съемочной аппаратуры, которые зачастую неизвестны в полном объеме, так и разметки области интереса на самом РЛИ. Дополнительно к обозначенным моментам при формировании модели ASC необходим учет окружения цели, ее текстуры, эффекта анизотропии и возможного появления радиолокационных теней, [214, 213]. Распознавание образов с применением моделей ASC подразумевает обработку матриц большого размера, и оптимизация этой процедуры требует самостоятельных исследований, в качестве примера можно привести применение квазиньютоновских методов [213].

#### **1.5.8. Выводы по разделу 1.5**

Анализ работ, посвященных применению различных методов обучения с учителем в задачах распознавания и классификации РЛИ, показывает, что существует большое количество разнообразных алгоритмов, основанных на использовании эталонных выборок, как параметрических, так и непараметрических. При использовании любого из них в задачах распознавания образов на РЛИ возникает необходимость выбора между скоростью (как обработки, так и обучения) и точностью получаемых результатов. Наиболее качественные результаты классификации и распознавания могут быть получены с использованием методов опорных векторов и моделей ASC, причем в ряде случаев получаемые с их помощью результаты превосходят искусственные нейронные сети [36, 189, 193, 215]. Однако оба этих метода являются не только вычислительно трудоемкими, но и требующими существенных временных затрат как на подготовку исходных данных, так и на решение вопросов, связанных с оптимизацией вычислений. Кроме того, в задачах классификации РЛИ точность метода опорных векторов обратно пропорциональна количеству распознаваемых классов [39, 194]. При работе с десятью и более классами достаточно эффективно проявляет себя метод «случайный лес», однако и его применение требует значительных вычислительных ресурсов.

#### **1.6. Глубокое обучение**

Общие идеи методов глубокого обучения основаны на моделировании высокоуровневых абстракций в противовес алгоритмам, ориентированным на конкретные узкоспециализированные задачи. Несмотря на то, что значительная часть алгоритмов этой группы методов была разработана еще в 70-ые годы прошлого века, значительная интеграция подходов глубокого обучения в процесс распознавания образов начала происходить только с середины 00-ых годов XXI века, что обусловлено, в первую



очередь, существенным ростом вычислительных мощностей того времени. Основным преимуществом использования методов глубокого обучения в задачах распознавания образов является их сквозной характер, включающий в себя обнаружение признаков, их описание и дальнейшее соотнесение с имеющейся иерархической структурой. Применительно к задачам обработки РЛИ в качестве глубоких методов чаще всего используются искусственные нейронные сети.

Искусственная нейронная сеть (ИНС) представляет собой математическую модель в виде программно-аппаратного воплощения, отображающую принципы сети нервных клеток живых организмов. Традиционные ИНС формализованы в виде системы объединенных искусственных нейронов, каждый из которых задействован только в обработке и формировании входящего и исходящего на него сигналов. В контексте ИНС принято выделять понятие ее обучения в противоположность общепринятым методам программирования, при этом процедура обучения заключается в нахождении весовых коэффициентов между отдельными нейронами. Такой подход позволяет выполнять существенное обобщение полученных результатов, что позволяет находить верное решение даже в условиях неполноты анализируемых данных. Применительно к задаче распознавания образов на изображениях, как правило, применяются свёрточные нейронные сети, относящиеся к алгоритмам обучения с учителем и основанные на использовании процедуры свёртки [220].

### **1.6.1. Свёрточные нейронные сети**

В основе свёрточных нейронных сетей (Convolutional Neural Network, CNN) лежит идея чередования двух типов слоёв: свёрточных слоёв (Сслоев) и субдискредитирующих слоёв (S-слоев), при этом на вход каждого из нейронов подается лишь определенный фрагмент исходного изображения, что позволяет сохранить топологию изображения внутри архитектуры сети. Обозначенные фрагменты изображения поэлементно перемножаются на ядро свертки, при этом полученный результат суммируется и записывается в соответствующую позицию выходного изображения. Такой подход позволяет сохранять инвариантность процедуры распознавания относительно операций сдвига, поворота и масштабирования, позволяя выявлять все более крупные и обобщенные структуры изображения. Концепция разделяемых весов в CNN-сетях предполагает использование ограниченного набора весов для существенного количества связей, что позволяет, с одной стороны, снизить требования к вычислительным ресурсам, с другой, уменьшить количество настраиваемых параметров. Тем не менее, возможен подход, при котором управление весами осуществляется с предшествующих уровней, за счет чего устанавливаются дополнительные связи в архитектуре сети, позволяющие добиться точности распознавания до 99 % [221]. Субдискретизация слоев заключается в уменьшении пространственной размерности изображения по мере углубления сети, а чередование слоев обеспечивает формирование карты признаков, полученной на основе атрибутивных данных предыдущего слоя, за счет чего достигается процедура распознавания сложных иерархических связей. В качестве метода вычисления градиента, использующегося при обновлении весов перцептрона, как правило, используется метод обратного распространения ошибки [90, 222], функция активации нейрона в общем случае может быть произвольной, однако чаще всего используются нелинейные функции, например функция гиперболического тангенса или радиальная базисная функция [223].

Использование свёрточных нейронных сетей в задачах распознавания образов позволяет получить результаты куда более достоверные в сравнении с традиционными методами обучения с учителем, в частности, на примере обнаружения объектов базы MSTAR на отдельных объектах точность достигает 96 % и выше [221–227]. Основным фактором возникновения ошибок классификации по-прежнему является наличие спекл-шума на РЛИ, в связи с чем для достижения наилучших результатов требуется предварительная пространственная фильтрация, с использованием, например, фильтра Ли и фильтра Фроста [226, 228]. В отличие от традиционных методов обучения с учителем, основанных на единственном целевом изображении, ИНС позволяют объединять РЛИ, полученные с различных ракурсов [229], при этом каждый угол обзора соответствует отдельному входу на нейронную сеть, а уже в ходе обучения выполняется объединение в единую карту признаков. Для повышения точности распознавания возможна модификация традиционных свёрточных нейронных сетей, например, добавление перцептронов с дополнительными слоями [230], а также сочетание процесса обучения с иными, более традиционными подходами к распознаванию образов, что позволяет улучшить разделимость классов. Это могут быть как методы без учителя [231–233], так и с учителем, например, метод опорных векторов [224, 234–236] либо модель ASC [237].

Однако при использовании любых вариаций метода CNN отмечается значительное время, требуемое на сам процесс обучения нейронной сети, что исключает возможность применения свёрточных нейронных сетей в режиме реального времени. Существуют разные подходы, позволяющие несколько ускорить процесс распознавания без существенных потерь точности, наиболее распространённый из них основан на дополнительном сжатии субдискредитирующих слоев [228, 238, 239]. В частности, в [238] показано, что сжатие S-слоев практически в 100 раз приводит к снижению точности распознавания не более, чем на 1 %, а производительность увеличивается почти в три раза. Еще одним приемом по ускорению процедуры обучения является уменьшение количества свёрточных слоев сети [225, 227, 228], что также дополнительно позволяет избежать эффектов переобучения сети. Наконец, могут оказаться полезными приемы, основанные на уменьшении размерности пространства признаков, таких как низкоранговое матричное разложение [227, 240] и адаптация функции потерь через линейный дискриминантный анализ [231].

Серьезной проблемой, возникающей при использовании свёрточных нейронных сетей, является недостаточный объем обучающей выборки, что приводит к переобучению сети и дальнейшему снижению ее эффективности при работе с реальными изображениями. Для увеличения обучающей выборки применяются различные подходы, например использование тестовых изображений с наложенным спекл-шумом [226, 241], расширение обучающей выборки за счет изображений земной поверхности, полученных в оптическом диапазоне [234, 242–245]. Еще одним методом увеличения обучающей выборки для метода CNN является использование генеративно-сопоставительных нейронных сетей (Generative Adversarial Network, GAN), основанных на совместном использовании двух типов архитектуры: сети G, отвечающей за формирование эталонных изображений на основании имеющейся выборки, и сети D, предназначенной для выявления таких изображений. Таким образом, состязательный эффект позволяет нарастить исходную выборку до необходимого объема в соответствии с заложенными критериями [246]. Наиболее удачное применение метода GAN заключается в наращивании выборки за счет добавления изображений, соответствующих

разным углам обзора [247], а также преобразованию изображения оптического диапазона в радиолокационный [248]. Искусственное увеличение обучающей выборки позволяет избежать переобучения и улучшить точность классификации, однако требует значительных дополнительных временных затрат.

### **1.6.2. Автокодировщики**

Автокодировщики представляют собой группу искусственных нейронных сетей, использующих подход обучения без учителя. Базовая архитектура автокодировщика содержит три слоя: входной (энкодер), промежуточный и выходной (декодер), причем количество нейронов в энкодере и декодере должны совпадать. На промежуточный слой при этом накладывается ряд ограничений, как правило, заключающихся либо в снижении его размерности, например, с помощью Фурье- или вейвлет-преобразований [249], либо разреженности активации, за счет чего при восстановлении данных, поступающих с декодера, достигается обобщение исходных данных. Как следует из описания принципа работы автокодировщиков, их основное предназначение заключается в снижении размерности признаков, причем зачастую такой подход оказывается более эффективным в сравнении с традиционными методами, такими как метод главных компонент и марковских случайных полей [250]. В задачах классификации РЛИ автокодировщики, как правило, используются в качестве элемента архитектуры основной свёрточной нейронной сети в случае значительной ее глубины, позволяя сократить временные ресурсы, необходимые для ее достаточного обучения [251, 252]. Подобно методам сегментации изображений, автокодировщики могут быть использованы как самостоятельный инструмент для нахождения изменений по разновременным РЛИ, однако в этом случае для снижения ошибок ложного срабатывания, вызванных присутствием спекл-шума на изображениях, метод требует дополнительных модификаций. В качестве примера можно привести использование линейного дискриминанта Фишера в качестве разрешающего правила [149], объединение с методом кластеризации К-средних [253] или С-средних [254].

### **1.6.3. Ограниченная машина Больцмана**

Машина Больцмана (Boltzmann Machine, BM) является разновидностью искусственной нейронной сети, позволяющей определять распределение вероятностей на исходных данных и, подобно автокодировщикам, реализующей подход обучения без учителя [255]. Базовая архитектура состоит из двух слоев, скрытого и видимого, причем в целях уменьшения ресурсов на обучение допустимы только межслойные нейронные связи (ограниченная машина Больцмана, Restricted Boltzmann Machine, RBM), а скрытый слой машины содержит в себе признаки, которые и устанавливаются в процессе обучения [256]. Вероятность активации каждого из нейронов определяется через функцию Больцмана, распределение значений нейронов видимого слоя в задачах, связанных с обработкой РЛИ, как правило, задается распределением Гаусса или, в случае мультиполяризационных данных — Уишарта [255, 257]. В начальный момент времени состояние нейронов соответствует входному распределению данных, а далее ищется состояние сети, соответствующее минимуму энергии (тепловой шум в терминологии архитектуры сети), причем на низких температурах для достижения наилучшего решения приходится большее число итераций. Как и в случае с автокодировщиками, в задачах распознавания образов по РЛИ ограниченные машины Больцмана применяются на этапе предварительного обучения основной нейронной сети,



либо в качестве одного из формирующих каскадов глубокой сети доверия [255, 257], Метод RBM может использоваться самостоятельно в задачах обнаружения изменений по разновременным космоснимкам [258] либо в сочетании с другими методами глубокого обучения, например, AbaBoost [156].

#### **1.6.4. Глубокая сеть доверия**

Глубокая сеть доверия (Deep Belief Network, DBN) представляет собой объединение нескольких каскадов сетей, основанных на обучении без учителя, в роли которых выступают автокодировщики, либо ограниченные машины Больцмана [154, 257, 259–261]. Такой тип сети содержит в себе несколько скрытых слоев, причем допустимы только межслойные нейронные связи. Обучение реализуется послойно (алгоритм жадного обучения), в ходе расчета весовых коэффициентов используется метод обратного распространения ошибки в сочетании с контрастной дивергенцией (CD). Такой подход позволяет более точно настраивать веса, с учетом различных особенностей образа на РЛИ, вызванных вариацией угла обзора [3]. Как правило, для достижения оптимальной точности достаточно использовать три или четыре скрытых слоя глубокой сети доверия [153, 259, 260, 262, 263]. Полученная архитектура может использоваться самостоятельно для сегментации РЛИ, например, в задачах выявления изменений [154, 257, 259, 261], выступать в роли предобучающего элемента перед применением свёрточной нейронной сети (глубокая свёрточная нейронная сеть) [260], применяться на последнем слое функции softmax, основанной на методе множественной логистической регрессии [153–155].

На сегодняшний день метод DBN является наиболее мощным решением в задачах сегментации РЛИ, демонстрируя на отдельных типах объектов земной поверхности точность распознавания, приближающуюся к 100 % [154, 257, 261, 263]. Однако, несмотря на гибкость и впечатляющие возможности обобщения в условиях существенного искажения исходных образов, общим недостатком глубоких сетей доверия является достаточно трудоемкий процесс обучения, потребляющий существенные вычислительные и временные ресурсы [259], а также необходимость разработки дополнительных алгоритмов, учитывающих всевозможную специфику используемых данных. В частности, предварительная нечеткая сегментация [154, 259, 261], морфологическая обработка [259, 261] и пространственная фильтрация, например, управляющим фильтром [153], позволяют как снизить размерность входных данных, так и уменьшить вероятность неверной их интерпретации в следствие спекл-шума.

#### **1.6.5. Рекуррентные нейронные сети**

Рекуррентные нейронные сети (Recurrent Neural Network, RNN) представляют собой тип ИНС, учитывающий инерционность входных данных. При этом выход каждого из нейронов определяется результатом предшествующих вычислений, а скрытый слой такой сети может быть интерпретирован как запоминание результатов вычислений некоторого количества предшествующих шагов. Нахождение весовых коэффициентов основано на вариации метода обратного распространения ошибки ВРТТ, а общее количество скрытых слоев определяется количеством итераций, заложенных в сети. При этом параметры вычислений остаются идентичными для каждого из слоев, что позволяет несколько сократить требования к вычислительным ресурсам. Функция активации может быть произвольной нелинейной функцией, например, сигмовидная функция или функция гиперболического тангенса [255].

Несмотря на то, что наиболее распространённым использованием рекуррентных нейронных сетей, является анализ временных последовательностей, в последние годы все чаще встречаются работы по их применению в задачах распознавания РЛИ. В частности, метод RNN показал себя как наиболее универсальный способ выявления закономерностей на РЛИ даже высокого пространственного разрешения, позволяющий сегментировать с точностью более 90 % даже такие анизотропные объекты, как дорожная сеть и сооружения [264]. Архитектура рекуррентных нейронных сетей может сочетаться с автокодировщиком, и тогда полученная модель выступает в роли инструмента сегментации РЛИ [264], либо со свёрточными нейронными сетями и сетями softmax [265, 266], а также иными методами обучения с учителем, например, методами разреженных представлений [267]. В случае применения подхода, основанного на обучении с учителем, высокая степень возможности обобщения исходных данных позволяет достичь точности распознавания на отдельных классах до 99 % [265], а универсальный набор параметров на различных итерациях сети RNN позволяет достичь сходимости в расчете весовых коэффициентов за сравнительно небольшое время по отношению к классическому методу CNN.

В литературе можно встретить и иные типы архитектур ИНН, используемых для классификации и распознавания образов, например, случайные нейронные сети (RnNN), остаточные нейронные сети (ResNet), сети радиально-базисных функций (RBF), глубокие каскадные сети на основе распределения Уишарта (W-DSN) и иные [255]. Все эти типы ИНН используются либо в сочетании со свёрточными нейронными сетями, либо с иными методами обучения с учителем, образуя различные гибридные архитектуры и направленные либо на сжатие размерности данных и последующее ускорения процедуры обучения, либо на учет ряда специфических особенностей, анализируемых РЛИ.

#### **1.6.6. AdaBoost**

AdaBoost представляет собой адаптивный мета-алгоритм машинного обучения, основанный на совместном применении нескольких алгоритмов слабой классификации. В качестве таких алгоритмов в задачах обработки РЛИ чаще всего выступают как классические методы обучения с учителем, например, метод максимального правдоподобия, метод минимального расстояния, метод  $k$  ближайших соседей, метод опорных векторов, «вращение леса» [40, 268–270], так и ИНС, такие как CNN и иные типы нейронных сетей, использующие в качестве классификатора, как правило, функцию softmax на последнем слое [40, 41, 156]. При этом каждый последующий шаг классификации выстраивается на основании неверно классифицированных объектов на предыдущем шаге посредством увеличения их весовых коэффициентов, таким образом на текущем шаге полученная модель оказывается сфокусированной на ошибочных объектах [41]. На последней итерации работы алгоритма AdaBoost будет сформирована архитектура из наиболее оптимальных по отношению к различным объектам классификаторов. Как правило, метод AdaBoost применяется по отношению к задаче обнаружения и/или детектирования определенных объектов. В частности, на примере обнаружения объектов базы MSTAR настоящий подход позволяет достигать точности распознавания до 99 % [40, 41, 269, 270], и показывает хорошую робастность по отношению к классическим методам обучения с учителем, например, методам опорных векторов [39]. Существенным недостатком метода AdaBoost является вероятность формирования излишне громоздкой композиции классификаторов,

включающей несколько сотен алгоритмов, что, с одной стороны, будет затруднять анализ полученной архитектуры, с другой стороны, будет требовать огромных объемов памяти и существенных временных затрат. Тем не менее, некоторые приемы позволяют привести к последующему снижению требований к вычислительным ресурсам, среди которых следует упомянуть предварительное применение к входным данным метода главных компонент и Фурье-преобразования для снижения их размерности [39–41], а также использование признаков Хаара [271].

#### **1.6.7. Генетический алгоритм**

Генетический алгоритм (Genetic Algorithm, GA) представляет собой форму эволюционных вычислений, использующийся для задач оптимизации и моделирования различных процессов с применением случайного подбора параметров, основанном на математическом моделировании процессов эволюции в живой природе. При использовании GA полагается, что решение может быть представлено в виде некоторых параметров (генов), объединённых в структуры данных (хромосомы). Гены могут быть выражены в виде двоичного кода, так и в виде алфавита, а структуры могут представлять собой строки, деревья либо матрицы. Множество потенциальных решений образует популяцию, которое совершенствуется с помощью генетических операторов, отвечающих за изменчивость, и целевой функции, моделирующей естественный отбор и служащей для оценки пригодности структуры данных. Как правило, целевая функция формализуется на основе принципа минимальной длины описания (MDL) [272, 273]. На начальной итерации формируется случайный набор хромосом, далее происходит формирование последующих поколений с учетом их приспособленности и изменчивости, на последнем шаге осуществляется выбор наилучших решений [274]. Применительно к задачам классификации изображений GA могут выступать как в роли инструмента обучения без учителя, так и использоваться для поиска наиболее эффективных признаков обучающей выборки. При интегрировании GA с алгоритмами обучения без учителя сегментация выступает в роли задачи оптимизации, в ходе которой GA позволяют эффективно анализировать гиперпространство признаков, находя с помощью целевой функции состояние с наибольшей разделимостью классов [273]. Так, сочетание GA с EM-алгоритмом позволяет получить на выходном продукте до 95 % адекватно сегментированных пикселей [272], а предварительное использование оператора Кэнни к исходному РЛИ и оптимизация целевой функции под задачу поиска контуров позволяет эффективно обнаруживать границы дорожной сети даже на данных РЛИ высокого разрешения [275].

В случае подхода, основанного на обучении с учителем, генетические алгоритмы выступают в роли инструмента, позволяющего отобрать наиболее удачные признаки элементов обучающей выборки, что позволяет избежать эффекта переобучения и в конечном счете снизить вычислительные затраты [216, 273, 276, 277]. В качестве классификатора при этом могут выступать различные рассмотренные выше методы, например, байесовский классификатор [273], метод разреженных представлений [216], сети радиально-базисных функций (RBF) [277]. Дополнительные приемы, такие как вейвлет преобразование элементов обучающей выборки [277] и предварительная свертка между фрагментами обучающей выборки и моделями ASC, на примере объектов базы MSTAR позволяют достичь точности распознавания до 95 % и выше [216, 276].

Несмотря на то, что генетические алгоритмы позволяют решать неформализованные задачи и в сочетании с другими методами классификации изображений позволяют

достичь высокой точности распознавания, сама процедура организации эволюционных вычислений достаточно трудоемкая, а их применение не гарантирует того, что итоговое решение окажется оптимальным [278]. Также следует отметить, что процедура оптимизации признаков обучающей выборки, предназначенной для сокращения времени процедуры распознавания, может потребовать существенного времени для достижения приемлемой сходимости. Таким образом, применение генетических алгоритмов оказывается оправданным тогда, когда необходимо получить приемлемый результат за сравнительно небольшое время, поэтому в последние годы в задаче распознавания образов на изображениях ГА встречаются все реже.

### **1.6.8. Вывод по разделу 1.6**

Использование методов глубокого обучения, основанных на ИНС, в задачах распознавания РЛИ является наиболее мощным инструментом, обеспечивающим точность распознавания на отдельных типах объектов до 99 % и выше. Однако следует отметить, что применительно к радиолокационным данным для достижения столь впечатляющих результатов любая архитектура нейронных сетей по-прежнему требует учета специфики данных в виде чувствительности к ракурсу и наличию спекл-шума и не может быть использована без предварительных модификаций. Процесс обучения ИНС является достаточно трудоемким процессом даже с учетом применения различных приемов по отношению к входным данным, таких как уменьшение размерности пространства признаков и использование генетических алгоритмов, поэтому методы глубокого обучения к задачам распознавания образов на РЛИ не могут быть применены в режиме реального времени. Еще одним существенным недостатком использования ИНС является требование к большому объему обучающей выборки (несколько тысяч элементов и более), в противном случае нейронная сеть окажется переобученной, что может привести к точности распознавания даже более низкой, чем традиционными методами обучения с учителем. Таким образом, перед применением любой ИНС необходимо либо заблаговременно подготовить достаточное количество образцов для ее эффективного обучения, либо применять дополнительные приемы, например, расширять выборку за счет использования генеративно-состязательных сетей, что опять же требует временных ресурсов. Наконец, при работе с более-менее глубокой (содержавшей существенное количество слоев) ИНС раскрытие ее топологии представляется невозможным, что известно, как эффект черного ящика. Это означает, что ИНС представляет собой неидентифицируемую модель, что, в свою очередь, затрудняет оценку точности результатов ее работы.

### **1.7. Выводы к главе 1**

Анализ работ, посвященных различным методам классификации и распознавания РЛИ, позволяет сделать следующие выводы:

1. Не существует единых подходов к оценке надежности используемых алгоритмов. Подавляющее большинство работ содержит оценку точности, произведенную по некоторому набору тестовых данных, при этом аналитические исследования возможностей приведенных методов, как правило, отсутствуют, а выбор оптимального метода зачастую осуществляется лишь по принципу сравнения между конкурирующими алгоритмами;

2. В работах, содержащих анализ точности, как правило, анализируются расчетные величины ошибок ложного срабатывания и ошибок пропуска, а также различных зависимостей, полученных на их основе, в то время как современные задачи распознавания образов выходят за пределы бинарного подхода к анализу полученных результатов и требуют более гибкого инструмента для оценки потенциальных возможностей используемых алгоритмов;

3. Обзор литературы показывает, что при выборе конкретного метода классификации необходимо искать компромисс между точностью получаемых результатов и скоростью вычислений, причем замедлению вычислений способствуют как подготовка и анализ исходных данных, так и сама расчетная процедура. Учитывая активное расширение задач, в которых находит свое применение область ДЗЗ, вопрос оперативности получаемых результатов встает особенно остро, и несмотря на то, что глубокие методы обучения позволяют распознавать объекты на РЛИ с точностью, приближающуюся к 100 %, зачастую оператор не располагает временем, необходимым для должной подготовки опорных данных;

4. Существующие работы по распознаванию образов и классификации РЛИ содержат экспериментальный раздел, посвященный использованию алгоритмов применительно к конкретным типам объектов, причем в качестве таких объектов в значительной части исследований выступают военные транспортные средства базы MSTAR, геометрические, яркостные и структурные параметры которых являются достаточно специфичными. Это позволяет сделать вывод об узкой направленности приведенных в главе алгоритмов, тогда как реальные природные объекты могут обладать существенной изменчивостью даже в пределах одной сцены;

5. За исключением задач, посвященных поиску изменений на разновременных РЛИ, существующие работы посвящены методам, предназначенным для обработки единичного кадра, в то время как в современной тенденции развития космонавтики предполагается активное внедрение группировок малых спутников. Такой подход позволит существенно расширить потенциал в распознавании образов, и современные подходы к обработке РЛИ должны быть адаптированы под меняющуюся ситуацию.

Анализ опубликованных работ позволяет сделать вывод о необходимости разработки принципиально новых подходов с учетом современных тенденций, которые позволяли бы, с одной стороны, осуществлять высокоточное распознавание образов на РЛИ в режиме реального времени, с другой стороны, позволяли бы выполнять гибкую оценку точности без привлечения тестовых данных.

## **1.8. Литература к главе 1**

1. В. Соифлер, Ред., Методы компьютерной обработки изображений, М.: Физматлит, 2003, р. 784.
2. Г. Кондратенков, Радиолокационные станции обзора Земли, В. П. и д. Г.С. Кондратенков, Ред., М.: Радио и связь, 1983, р. 272.
3. O. Kechagias-Stamatis, «Automatic Target Recognition on Synthetic Aperture Radar Imagery: A Survey», Computer Vision and Pattern Recognition, т. 36, № 3, pp. 56–81, 2021.
4. Xiao Yuan, Tao Tang, Deliang Xiang, Yu Li, Yi Su, «Target recognition in SAR imagery based on local gradient ratio pattern», International Journal of Remote Sensing, т. 35, № 3, p. 857–870, 2014.



5. Kuiying Yina, Lin Jina, Changchun Zhanga, Yufeng Guob, «A method for automatic target recognition using shadow contour of SAR image», IETE Technical Review, т. 30, № 4, pp. 313-323, 2013.
6. Gholamreza Akbarizadeh, «A New Statistical-Based Kurtosis Wavelet Energy Feature for Texture Recognition of SAR Images», IEEE transactions on geoscience and remote sensing, т. 50, № 11, pp. 4358-4368, 2012.
7. Armando Marino, Maria J. Sanjuan-Ferrer, Irena Hajnsek, Kazuo Ouchi, «Ship Detection with Spectral Analysis of Synthetic Aperture Radar: A Comparison of New and Well-Known Algorithms», Remote sensing, т. 7, pp. 5416-5439, 2015.
8. Min Dai, Cheng Peng, Andrew K. Chan, Dmitri Loguinov, «Bayesian Wavelet Shrinkage With Edge Detection for SAR Image Despeckling», IEEE transactions on geoscience and remote sensing, т. 42, № 8, pp. 1642-1648, 2004.
9. Alin Achim, Panagiotis Tsakalides, Anastasios Bezerianos, «SAR Image Denoising via Bayesian Wavelet Shrinkage Based on Heavy-Tailed Modeling», IEEE transactions on geoscience and remote sensing, т. 41, № 8, pp. 1773-1784, 2003.
10. S.K. Pal, T.J. Majumdar, A.K. Bhattacharya, «Extraction of linear and anomalous features using ERS SAR data over Singhbhum Shear Zone, Jharkhand using fast Fourier», International Journal of Remote Sensing, т. 27, № 20, p. 4513-4528, 2006.
11. Ganggang Dong, Hongwei Liu, Gangyao Kuang, Jocelyn Chanussot, «Target recognition in SAR images via sparse representation in the frequency domain», Pattern Recognition, 2019.
12. V. Namias, «The fractional order Fourier transform and its application to quantum mechanics», Journal of Institute of Mathematics and its Applications, № 25, pp. 241-265, 1980.
13. J. Radon, «Über die Bestimmung von Funktionen durch ihre Integralwerte längs gewisser Mannigfaltigkeiten», Berichte Sächsische Akademie der Wissenschaften, № 69, p. 262-277, 1917.
14. A.C. Copeland, G. Ravichandran, M.M. Trivedi, «Localized Radon Transform-Based Detection of Ship Wakes in SAR Images», IEEE Transactions on Geoscience and Remote Sensing, т. 33, № 1, pp. 35-45, 1995.
15. P. Courmontagne, «An improvement of ship wake detection based on the radon transform», Signal Processing, т. 85, № 8, pp. 1634-1654, 2005.
16. Yunping Chen, Yang Li, Huixiong Zhang, Ling Tong, Yongxing Cao, Zhihang Xue, «Automatic power line extraction from high resolution remote sensing imagery based on an improved Radon transform», Pattern Recognition, т. 49, pp. 174-186, 2016.
17. L. M. Murphy, «Linear feature detection and enhancement in noisy images via the Radon transform», Pattern Recognition, т. 4, № 4, pp. 279-284, 1986.
18. G. O. L. L. P. E. Magli, «Pattern recognition by means of the Radon transform and the continuous wavelet transform», Signal Processing, т. 73, pp. 277-289, 1999.
19. H. P.V.C., «Methods, Means for Recognizing Complex Patterns». U.S. Патент 3069654, 1962.
20. D. Ballard, «Generalizing the Hough transform to detect arbitrary shapes», Pattern Recognition, т. 13, № 2, pp. 111-122, 1981.
21. J. Skingley, A.J. Rye, «The Hough transform applied to SAR for thin line detection», Pattern Recognition, т. 6, pp. 61-67, 1987.
22. Y. Pi, L. Fan, X. Yang, «Geoscience and Remote Sensing Symposium», в Airport Detection and Runway Recognition in SAR Images, 2003.

23. J. Cheng-Li, J. Ke-Feng, J. Yong-Mei, K. Gang-Yao, «International Geoscience and Remote Sensing Symposium», в Road Extraction from High-Resolution SAR Imagery Using Hough, 2005.
24. S. Mallat, «A theory for multiresolution signal decomposition: the wavelet representation», Transactions on Pattern Analysis and Machine Intelligence, т. 11, № 7, pp. 674-693, 1989.
25. G. Dong, G. Kuang, N. Wang, W. Wang, «Classification via Sparse Representation of Steerable Wavelet Frames on Grassmann Manifold: Application to Target Recognition in SAR Image», IEEE transactions on image processing, т. 20, № 20, pp. 1-13, 2017.
26. M. Tello, C. Lopez-Martinez, J.J. Mallorqui, «A Novel Algorithm for Ship Detection in SAR Imagery Based on the Wavelet Transform», IEEE Geoscience and Remote Sensing Letters, т. 2, № 2, pp. 201-205, 2005.
27. J.-P. Ovarlez, L. Vignaud, J.-C. Castelli, M. Tria, M. Benidir, «Analysis of SAR images by multidimensional wavelet transform», Radar, Sonar and Navigation, т. 150, № 4, p. 234-241, 2003.
28. F. Bovolo, L. Bruzzone, «A Detail-Preserving Scale-Driven Approach to Change Detection in Multitemporal SAR Images», IEEE Transactions on Geoscience and Remote Sensing, т. 43, № 12, pp. 2963-2972, 2005.
29. Z. Zhou, M. Wang, Z. Cao, Y. Pi, «SAR Image Recognition with Monogenic Scale Selection-Based Weighted Multi-task Joint Sparse Representation», Remote Sensing, т. 10, pp. 504-513, 2018.
30. G. Dong, G. Kuang, N. Wang, G. Dong, G. Kuang, N. Wang, L. Zhao, J. Lu, «SAR Target Recognition via Joint Sparse Representation of Monogenic Signal», IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, т. 8, № 7, pp. 3316-3328, 2015.
31. F. Chatelain, J.-Y. Tourneret, J. Inglada, «Change Detection in Multisensor SAR Images Using Bivariate Gamma Distributions», IEEE transactions on image processing, т. 17, № 3, pp. 249-258, 2008.
32. M Amoon, GA Rezai-Rad, «Automatic target recognition of synthetic aperture radar (SAR) images based on optimal selection of Zernike moments features», IET Computer Vision, т. 8, № 2, p. 77-85, 2014.
33. XZ Zhang, Z Liu, S Liu, D Li, Y Jia, «Sparse coding of 2D-slice Zernike moments for SAR ATR», International journal of remote sensing, т. 38, № 2, p. 412-431, 2017.
34. Bolourchi P., Moradi M., Demirel H., Uysal S., «20th International Conference on Modelling & Simulation», в Random Forest Feature Selection for SAR ATM, 2018.
35. K. P. F.R.S., «On lines and planes of closest fit to systems of points in space», Philosophical Magazine, т. 2, p. 559-572, 1901.
36. Qun Zhao, Jose C. Principe, Victor Brennan, Dongxin Xu, Zheng Wang, «Synthetic Aperture Radar Automatic Target Recognition with Three Strategies of Learning and Representation», Optical Engineering, т. 39, № 5, 2000.
37. Wu Tao, Chen Xi, Ruang Xiangwei, Niu Lei, «Study on SAR Target Recognition Based on Support Vector Machine», в 2nd Asian-Pacific Conference on Synthetic Aperture Radar, 2009.
38. P Du, A Samat, B Waske, S Liu, Z Li, «Random Forest and Rotation Forest for fully polarized SAR image classification using polarimetric and spatial features», ISPRS Journal of Photogrammetry and Remote Sensing, т. 105, pp. 38-53, 2015.

39. Ying Wang, Ping Han, Xiaoguang Lu, Renbiao Wu, Jingxiong Huang, «The Performance Comparison of Adaboost and SVM Applied to SAR ATR», в CIE International Conference on Radar, 2007.
40. Zhang F., Wang Y., Ni J., Zhou Y., «SAR Target Small Sample Recognition Based on CNN Cascaded Features and AdaBoost Rotation Forest», IEEE geoscience and remote sensing letters, т. 17, № 6, pp. 1008-1012, 2020.
41. Sun Y., Liu Z., Todorovic S., Li J., «Adaptive Boosting for SAR Automatic Target Recognition», IEEE Transactions on Aerospace and Electronic Systems, т. 43, № 1, pp. 112-125, 2007.
42. C. P., «Independent Component Analysis: a new concept?», Signal Processing, т. 36, № 3, p. 287–314, 1994.
43. Huang C.-W., Lee K.-C., «Application of ICA technique to PCA based radar target recognition», Progress In Electromagnetics Research, т. 105, p. 157–170, 2010.
44. Maokuan L., Jian G., Hui D., Xin G., «SAR ATR based on Support Vector Machines and Independent Component Analysis SVM», в CIE International Conference on Radar, 2007.
45. Hongyun Y., Jian G., Tao G., Jing Z., «SAR ATR based on Multi-Subspaces of Independent Component Analysis», в 1st Asian and Pacific Conference on Synthetic Aperture Radar, 2008.
46. «Sensor data management system website, MSTAR database», 1995. [В Интернете]. Available: <https://www.sdms.afrl.af.mil/index.php?collection=mstar>.
47. M. I., «Structured low-rank approximation and its applications», Automatica, т. 44, № 4, pp. 891-909, 2008.
48. Dang S., Cui Z., Cao Z., Liu N., «SAR Target Recognition via Incremental Nonnegative Matrix Factorization», Remote Sensing, т. 10, № 3, pp. 374-382, 2018.
49. Cui Z., Feng J., Cao Z., Yang J.M., «Target recognition in synthetic aperture radar images via non-negative matrix factorization», IET Radar, Sonar & Navigation, т. 9, № 9, 2015.
50. Yu M., Dong G., Fan H., Kuang G., «SAR Target Recognition via Local Sparse Representation of Multi-Manifold Regularized Low-Rank Approximation», Remote Sensing, т. 10, № 2, pp. 211-219, 2018.
51. Yu M., Zhang S., Zhang L., Zhao L., Kuang G., «SAR Target Recognition via Joint Manifold Regularized Low-Rank Matrix Approximation», в 19th International Radar Symposium (IRS), 2018.
52. Zhang X., Wang Y., Li D., Tan Z., Liu S., «Fusion of Multifeature Low-Rank Representation for Synthetic Aperture Radar Target Configuration Recognition», IEEE Geoscience and Remote Sensing Letters, т. 15, № 9, pp. 1402-1406, 2018.
53. Wang Y., Zheng Q., «Recognition of roads and bridges in SAR images», Pattern Recognition, т. 31, № 7, pp. 953-962, 1998.
54. Zaart A.I., Ziou D., Wang S., Jiang Q., «Segmentation of SAR images», Pattern Recognition, т. 35, p. 713–724, 2002.
55. J.Kittler J., Illingworth J., «Minimum error thresholding», Pattern Recognition, т. 19, № 1, pp. 41-47, 1986.
56. Dellepiane S., Giusto D.D., Serpico S.B., Vernazza G., «SAR image recognition by integration of intensity and textural information», International Journal of Remote Sensing, т. 12, № 9, pp. 1915-1932, 1991.
57. Bazi Y., Bruzzone L., Melgani F., «An unsupervised approach based on the generalized gaussian model to automatic change detection in multitemporal SAR images», IEEE Transactions on Geoscience and Remote Sensing, т. 43, № 4, pp. 874-887, 2007.

58. Akbarizadeh G., Rezai-Rad G.A., Shokouhi B., «A New region-Based active contour model with skewness wavelet energy for segmentation of SAR images», *IEICE Transactions on Information and Systems*, Т. 93-D, № 7, pp. 1690-1699, 2010.
59. H Tan, G Yang, N Zheng, T Luo, «An improvement of two-dimensional maximum entropy thresholding segmentation algorithm for SAR image», в *International Conference on Computer Science and Electronics Engineering*, Hangzhou, 2012.
60. R H. Nobre, F A. A. Rodrigues, R C. P. Marques, J S. Nobre, J F. S. R. Neto, F N. S. Medeiros, «SAR Image Segmentation With Renyi's Entropy», *Signal processing letters*, т. 23, № 11, pp. 1551-1555, 2016.
61. A Al-Ajlan, A El-Zaart, «Image segmentation using minimum cross-entropy thresholding», в *Proceedings of the 2009 IEEE International Conference on Systems, Man, and Cybernetics*, 2009.
62. Kekre H.B., Gharge S., Sarode T.K., «SAR Image Segmentation using Vector Quantization Technique on Entropy Images», *International Journal of Computer Science and Information Security*, т. 7, № 3, 2010.
63. Liu J Z, Li W Q, Tian Y P, «Automatic threshold of gray-level pictures using two-dimensional Otsu method», в *Proceedings of International Conference on Circuits and Systems*, Shenzhen, 1991.
64. Guo Y., Zhang J., «A new 2D Otsu for water extraction from SAR image», *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Т. 42, № 2/W7, pp. 733-736, 2017.
65. F Yu, W Sun, J Li, Y Zhao, Y Zhang, G Chen, «An improved Otsu method for oil spill detection from SAR images», *Oceanologia*, т. 59, № 3, pp. 311-317, 2017.
66. Q. Chen L. Zhao J. Lu G. Kuang N. Wang Y. Jiang, «Modified two-dimensional Otsu image segmentation algorithm and fast realisation», *ET Image Processing*, т. 6, № 4, p. 426-433, 2012.
67. L. S., «Least squares quantization in PCM», in *IEEE Transactions on Information Theory*, т. 28, № 2, pp. 129-137, 1982.
68. D Samanta, M Paul, G Sanyal, «Segmentation Technique of SAR Imagery using Entropy», *International Journal of Computer Applications in Technology*, т. 2, № 5, pp. 1548-1551, 2011.
69. Liu L., ia Zh., Yang J., Kasabov N.K., «SAR Image Change Detection Based on Mathematical Morphology and the K-Means Clustering Algorithm», *IEEE Access*, т. 7, pp. 43970-43978, 2019.
70. E. Niharika, H Adeeba, A.Sh R Krishna, P.Yugander, «K-means based Noisy SAR Image Segmentation using Median Filtering and Otsu Method», в *2017 International Conference on IoT and Application*, Nagapattinam, 2017.
71. J. C. Bezdek, «Pattern Recognition with Fuzzy Objective Function Algorithms», 1981.
72. Wan L., Zhang T., Xiang Y., You H., «A Robust Fuzzy C-Means Algorithm Based on Bayesian Nonlocal Spatial Information for SAR Image Segmentation», *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, т. 11, № 3, pp. 896-906, 2018.
73. R. Shang, Ch. Chen, G. Wang, L. Jiao, M.A. Okoth, R. Stolkin, «A thumbnail-based hierarchical fuzzy clustering algorithm for SAR image segmentation», *Signal Processing*, т. 171, pp. 1-9, 2020.
74. Gui Y., Zhang X., Shang Y., «SAR image segmentation using MSER and improved spectral clustering», *EURASIP Journal on Advances in Signal Processing*, т. 83, pp. 1-9, 2012.

75. Rahmani M., Akbarizadeh Gh., «Unsupervised feature learning based on sparse coding and spectral clustering for segmentation of synthetic aperture radar images», *IET Computer Vision*, т. 9, № 5, p. 629–638, 2015.
76. Liua, F. Zhao, L. Jiao H., «Fuzzy spectral clustering with robust spatial information for image segmentation», *Applied Soft Computing*, т. 12, № 11, pp. 3636–3647, 2012.
77. R. Shang, P. Tian, L. Jiao, R. Stolkin, J. Feng, B. Hou, X. Zhang, «A Spatial Fuzzy Clustering Algorithm With Kernel Metric Based on Immune Clone for SAR Image Segmentation», *IEEE Journal of selected topics in applied earth observations and remote sensing*, т. 9, № 4, pp. 1640–1652, 2016.
78. X Zhang, L Jiao, F Liu, L Bo, M Gong, «Spectral Clustering Ensemble Applied to SAR Image Segmentation», *IEEE Transactions on geoscience and remote sensing*, т. 46, № 7, pp. 2126–2136, 2008.
79. Sh. Gou, .X. Zhuang, H. Zhu, .T. Yu, «Parallel Sparse Spectral Clustering for SAR Image Segmentation», *IEEE Journal of selected topics in applied earth observations and remote sensing*, т. 6, № 4, pp. 1949–1963, 2013.
80. A. Baghi, A. Karami, «SAR image segmentation using region growing and spectral cluster», в *3rd International Conference on Pattern Recognition and Image Analysis*, 2017.
81. P. Yu, A.K. Qin, D.A. Clausi, «Clausi Unsupervised Polarimetric SAR Image Segmentation and Classification Using Region Growing With Edge Penalty», *IEEE Transactions on geoscience and remote sensing*, т. 50, № 4, pp. 1302–1317, 2012.
82. Sharma R., Sharma R., «Image Segmentation using Morphological Operations for Automatic Region Growing», *International Journal of Computer Science and Information Technologies*, т. 4, № 6, pp. 844–847, 2013.
83. J. Lira, L. Frulla, «An automated region growing algorithm for segmentation of texture regions in SAR images», *International Journal of Remote Sensing*, т. 19, № 18, pp. 3595–3606, 1998.
84. L. Li, X. Zhang, L. Pu, L. Pu, B. Tian, L. Zhou, Sh. Wei, «3D SAR Image Background Separation Based on Seeded Region Growing», *IEEE Access*, т. 7, pp. 179842–179863, 2019.
85. J. Yeom, M. Jung, Y. Kim, «Detecting damaged building parts in earthquakedamaged areas using differential seeded region growing», *International Journal of Remote Sensing*, т. 38, № 4, p. 985–1005, 2017.
86. Nock R., Nielsen F., «Statistical Region Merging», *IEEE Transactions on Pattern Analysis and Machine Intelligence*, т. 26, № 11, p. 1452–1458, 2004.
87. F Lang, J Yang, D Li, L Zhao, L Shi, «Polarimetric SAR Image Segmentation Using Statistical Region Merging», *IEEE Geoscience and remote sensing letters*, т. 11, № 2, pp. 509–513, 2014.
88. H Zhang, W Ni, W Yan, H Bian, J Wu, Sh Li, «SAR Image Change Detection using Modified Statistical Region Merging», в *4th International Conference on Computer Science and Network Technology*, Harbin, 2015.
89. Hu Y., Fan J., Wang J., «Target Recognition of Floating Raft Aquaculture», в *Seventh International Conference on Information Science and Technology*, 2017.
90. W. R.G., «Change detection in SAR imagery», *International Journal of Remote Sensing*, т. 12, № 2, pp. 339–360, 1991.
91. W. Li, G.B. Benie, D.-Ch. He, Sh. Wang, D. Ziou, Q. Hugh, J. Gwyn, «Watershed-based hierarchical SAR image segmentation», *International Journal of Remote Sensing*, т. 20, № 17, pp. 3377–3390, 1999.



92. R. Fjørtoft, A. Lopes, P. Marthon, E. Cubero-Castan, «An Optimal Multiedge Detector for SAR Image Segmentation», IEEE Transactions on geoscience and remote sensing, т. 36, № 3, pp. 793-802, 1998.
93. M. Kass, A. Witkin, D. Terzopoulos, «Snakes: Active Contour Models», International Journal of Computer Vision, pp. 321-331, 1998.
94. Zhang X. Xiong B., Dong G., Kuang G., «Ship Segmentation in SAR Images by Improved Nonlocal Active Contour Model», Sensors, т. 18, № 12, pp. 4220-434, 2018.
95. Tu, S.; Su, Y.; Li, Y., «Convex active contour model for target detection in synthetic aperture radar images», Journal of Applied Remote Sensing, т. 9, pp. 1-24, 2015.
96. Shuai, Y., Sun, H., Xu, G., «SAR image segmentation based on level set with stationary global minimum», IEEE Geoscience and remote sensing letters, т. 5, p. 644-648, 2008.
97. J. Liu, X. Wen, Q. Meng, H. Xu, L. Yuan, «Synthetic Aperture Radar Image Segmentation with Reaction Diffusion Level Set Evolution Equation in an Active Contour Model», Remote sensing, т. 10, pp. 1-16, 2018.
98. I.B. Ayed, C. Vdiquez, A. Mitiche, Z Belhacclj, «SAR image segmentation with active contours and level sets», в 2004 International Conference on Image Processing, 2004.
99. Ayed, I.B., Hennane, N., Mitiche, A., «Unsupervised variational image segmentation/classification using a Weibull observation model», IEEE Transactions on Image Processing, т. 15, p. 3431-3439, 2006.
100. H. Song, B. Huang, K. Zhang, «A Globally Statistical Active Contour Model for Segmentation of Oil Slick in SAR Imagery», IEEE Journal of selected topics in applied earth observations and remote sensing, т. 6, № 6, pp. 2402-2409, 2013.
101. G.-S. Xia, G. Liu, W. Yang, L. Zhang, «Meaningful Object Segmentation From SAR Images via a Multiscale Nonlocal Active Contour Model», IEEE Transactions on geoscience and remote sensing, т. 54, № 3, pp. 1860-1873, 2016.
102. O. Germain, Ph. Réfrégier, «Edge Location in SAR Images: Performance of the Likelihood Ratio Filter and Accuracy Improvement with an Active Contour Approach», IEEE Transactions on image processing, т. 10, № 1, pp. 72-78, 2001.
103. H. M.S., «A statistical active contour model for SAR image segmentation», Image and Vision Computing, т. 17, № 3-4, pp. 213-224, 1999.
104. B. Han, Y. Wu, «A novel active contour model driven by J-divergence entropy for SAR river image segmentation», Pattern Analysis and Applications, т. 21, p. 613-627, 2018.
105. U. Javed, M.M. Riaz, A. Ghafoor, T.A. Cheema, «SAR Image Segmentation Based on Active Contours With Fuzzy Logic», IEEE Transactions on aerospace and electronic systems, т. 52, № 1, pp. 181-188, 2016.
106. Y. Wu, W. Ma, M. Gong, H. Li, L. Jiao, «Novel fuzzy active contour model with kernel metric for image segmentation», Applied Soft Computing, т. 34, pp. 301-311, 2015.
107. B. Han, Y. Wu, A. Basu, «Adaptive Active Contour Model Based on Weighted RBPF for SAR Image Segmentation», IEEE Access, т. 7, pp. 54522-54532, 2019.
108. Q. Meng, X. Wen, L. Yuan, H. Xu, «Factorization-Based Active Contour for Water-Land SAR Image Segmentation via the Fusion of Features», IEEE Access, т. 7, pp. 40347-40358, 2019.
109. P.C. Smits, S.G. Dellepiane, «Synthetic aperture radar image segmentation by a detail preserving Markov random field approach», IEEE Transactions on Geoscience and Remote Sensing, т. 35, № 4, pp. 844-857, 1997.
110. L. S.Z., Markov random field modeling in computer vision, Tokyo: Springer-Verlag, 1995.

111. O Lankoande, MM Hayat, B. Santhanam, «Segmentation of SAR Images Based on Markov Random Field Model», в IEEE International Conference on Systems, Man and Cybernetics, Waikoloa, USA, 2005.
112. X. Lei, Y. Li, N. Zhao, Y. Zhang, «Fast segmentation approach for SAR image based on simple Markov random field», Journal of Systems Engineering and Electronics, т. 21, № 1, p. 31–36, 2010.
113. P. Zhanga, M. Lia, Y. Wub, L. Ana, L. Jia, «Unsupervised SAR Image Segmentation Using High-Order Conditional Random Fields Model based on Product-of-Experts», Pattern Recognition Letters, т. 78, № 15, pp. 48-55, 2016.
114. P. Zhang, M. Li, Y. Wu, H. Li, «Hierarchical Conditional Random Fields Model for Semisupervised SAR Image Segmentation», IEEE transactions on geoscience and remote sensing, т. 53, № 9, pp. 4933-4951, 2015.
115. M. Li, Y. Wub, Q. Zhang, «SAR image segmentation based on mixture context and wavelet hidden-class-label Markov random field», Computers and Mathematics with Applications, т. 57, № 6, pp. 961-969, 2009.
116. G.-S. Xia, C. He, H. Sun, «Integration of synthetic aperture radar image segmentation method using Markov random field on region adjacency graph», IET Radar Sonar Navigation, т. 1, № 5, pp. 348-353, 2007.
117. Q. Yu, D.A. Clausi, «IRGS: Image Segmentation Using Edge Penalties and Region Growing», IEEE Transactions on pattern analysis and machine intelligence, т. 30, № 12, pp. 2126-2139, 2008.
118. D.A. Clausi, B. Yue, «Comparing Cooccurrence Probabilities and Markov Random Fields for Texture Analysis of SAR Sea Ice Imagery», IEEE transactions on geoscience and remote sensing, т. 42, № 1, pp. 214-228, 2004.
119. R. Zhang, M. Zhang, «SAR target recognition based on active contour without edges», Journal of Systems Engineering and Electronics, т. 28, № 2, p. 276–281, 2017.
120. H. T. Li, H.Y. Gu, Y. S. Han, J. H. Yang, «Object-oriented Classification of Polarimetric SAR Imagery based on Statistical Region Merging and Support Vector Machine», в International Workshop on Earth Observation and Remote Sensing Applications, Beijing, 2008.
121. F. Lang, J. Yang, L. Zhao, D. Li, «Hierarchical classification of polarimetric SAR image based on statistical region merging», ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, т. 1, № 7, pp. 147-152, 2012.
122. П. Х. Р. Дуда, Распознавание образов и анализ сцен, В. Стефанюк, Ред., М.: Мир, 1976, p. 507.
123. Скрыпник О.Н., Лежанкин Б.В., Малов А.Н., Миронов Б.М., Галиев С.Ф., «Формирование классификационной карты подстилающей поверхности по изображениям от когерентного локатора», Компьютерная оптика, т. 29, pp. 151-159, 2006.
124. Chen Ch., Huang K., Gao G., «Small-Target Detection between SAR Images Based on Statistical Modeling of Log-Ratio Operator», Sensors, т. 19, № 6, pp. 1431-1440, 2019.
125. Oh J., Youm G.Y., Kim M., «SPAM-Net: A CNN-Based SAR Target Recognition Network With Pose Angle Marginalization Learning», IEEE transactions on circuits and systems for video technology, т. 31, № 2, pp. 701-714, 2021.
126. Huang P., Qiu W., «A robust decision fusion strategy for SAR target recognition», Remote Sensing Letters, т. 9, № 6, p. 507–514, 2018.
127. Chiang H.-C., Moses R.L., Potter L.C., «Model-based Bayesian feature matching with application to synthetic aperture radar target recognition», Pattern Recognition, т. 34, № 8, pp. 1539-1553, 2001.

128. Liu J., Chang K.-C., «Feature-Based Target Recognition with Bayesian Inference», в Uncertainty Modeling and Analysis, International Symposium, 1995.
129. Kullback S., Leibler R.A., «On information and sufficiency», The Annals of Mathematical Statistics, т. 22, № 1, pp. 79-86, 1951.
130. Song Sh., Xu B., Li Z., Yang J., «Ship Detection in SAR Imagery via Variational Bayesian Inference», IEEE Geoscience and Remote Sensing Letters, т. 13, № 3, pp. 319-323, 2016.
131. К. С. А. Л. С. А. Коренной А.В., «Способ распознавания и определения параметров образа объекта на радиолокационном изображении». Российская Федерация Патент RU 2516000 C2, 20 май 2014.
132. Q. W. Huang P., «A robust decision fusion strategy for SAR target recognition», Remote Sensing Letters, т. 9, № 6, p. 507–514, 2018.
133. Liu J., Chang K.-C., «Automatic Target Recognition with Bayesian Networks», в IFAC Proceedings Volumes, 1996.
134. Ruohong Huan, Yun Pan, Keji Mao, «SAR Image Target Recognition Based on NMF Feature Extraction and Bayesian Decision Fusion», в Second IITA International Conference on Geoscience and Remote Sensing, 2010.
135. Ma W., Wu Y., Gong M., Xiong Y., «Change detection in SAR images based on matrix factorisation and a Bayes classifier», International Journal of Remote Sensing, т. 40, № 4, pp. 1-26, 2018.
136. Jia M., Wang L., «Novel class-relativity non-local means with principal component analysis for multitemporal SAR image change detection», International Journal of Remote Sensing, т. 39, № 4, pp. 1068-1091, 2018.
137. Liping Hu and Xiaoyu Xing, «SAR target feature extraction and recognition based multilinear principal component ana», в Proc. SPIE 9301, International Symposium on Optoelectronic Technology and Application 2014: Image Processing and Pattern Recognition, 2014.
138. Ch. Lin, F. Peng, B.-H. Wang, W.-F. Sun, X.-J. Kong, «Research on PCA and KPCA Self-Fusion Based MSTAR SAR Automatic Target Recognition Algorithm», Journal of electronic science and technology, т. 10, № 4, pp. 352-357, 2012.
139. Monga V., Raj R.G., «SAR Automatic Target Recognition Using Discriminative Graphical Models», IEEE transactions on aerospace and electronic systems, т. 50, № 1, pp. 591-606, 2014.
140. Liu H., Li Sh., «Decision fusion of sparse representation and support vector machine for SAR image target recognition», Neurocomputing, т. 113, p. 97–104, 2013.
141. K Dai, W Lyu, S Luo, Q Shi, «Bayesian sparse representation model for SAR image classification», Journal of Applied Remote Sensing, т. 13, № 4, 2019.
142. Li C., Guohua Liu G., «Block Sparse Bayesian Learning over Local Dictionary for Robust SAR Target Recognition», International Journal of Optics, 2020.
143. Ren H., Yu X., Bruzzone L., Zhang Y., Zou L., Wang X., «A Bayesian Approach to Active Self-Paced Deep Learning for SAR Automatic Target Recognition», IEEE geoscience and remote sensing letters, 2020.
144. Chen S., Wang H., «SAR Target Recognition Based on Deep Learning», в International Conference on Data Science and Advanced Analytics (DSAA), Shanghai, 2014.
145. Bolourchi P., Moradi M., Demirel H., Uysal S., «Improved SAR target recognition by selecting moment methods based on Fisher score», Signal, Image and Video Processing, т. 14, pp. 39-47, 2020.

146. Han P., Wu R., Wang Y., Wang Zh., «An efficient SAR ATR approach», в IEEE International Conference on Acoustics, Speech, and Signal Processing, Hong Kong, 2003.
147. R. Huan, R. Liang and Y. Pan, «SAR Target Recognition with the Fusion of LDA and ICA», в International Conference on Information Engineering and Computer Science, Wuhan, 2009.
148. He J., Wang Y., Liu H., «Ship Classification in Medium-Resolution SAR Images via Densely Connected Triplet CNNs Integrating Fisher Discrimination Regularized Metric Learning», IEEE Transactions on Geoscience and Remote Sensing, т. 59, № 4, pp. 3022-3039, 2021.
149. Liu G., Li L., Jiao L., «Stacked Fisher Autoencoder for SAR Change Detection», Pattern Recognition, т. 96, № 2, 2019.
150. J. S. Cramer, «The origins of logistic regression (Technical report)», Tinbergen Institute, т. 119, p. 167–178, 2002.
151. Borghys D., Yvinec Y., Perneel C., «Supervised Feature-Based Classification of Multi-Channel SAR Images», Pattern Recognition Letters 27(4):, т. 27, № 4, pp. 252-258, 2005.
152. Albergaa V., Borghysa D., Satalinob G., Staykovac D.K., Borghgraefa A., Lapierre F., Perneel C., «Comparison of algorithms for the classification of polarimetric SAR data», в Proceedings of SPIE – The International Society for Optical Engineering, 2009.
153. Wang J., Liu J., Ren P., Qin Ch.-X., «A SAR Target Recognition Based on Guided Reconstruction and Weighted Norm-Constrained Deep Belief Network», IEEE Access, т. 8, pp. 181712-181722, 2020.
154. Ge S., Lu J., Gu H., Yuan Z., Su W., «Polarimetric SAR Image Classification Based on Deep Belief Network and Superpixel Segmentation», в 3rd International Conference on Frontiers of Signal Processing (ICFSP), Paris, 2017.
155. Lv Q., Dou Y., Niu X., Xu J., Li B., «Classification of land cover based on deep belief networks using polarimetric RADARSAT-2 data», в IEEE Geoscience and Remote Sensing Symposium, Quebec, 2014.
156. Qin, F., Guo, J., and Sun, W., «Object-oriented ensemble classification for polarimetric sar imagery using restricted boltzmann machines», Remote Sensing Letters, т. 8, № 3, p. 204–213.
157. Ding J., Chen B., Liu H., Huang M., «Convolutional Neural Network With Data Augmentation for SAR Target Recognition», IEEE geoscience and remote sensing letters, т. 13, № 3, pp. 364-368, 2016.
158. M. J. Minkler G., CFAR: The principles of automatic radar detection in clutter, Baltimore: Magellan Book Co., 1990, p. 384.
159. Touzi R., Lopes A., Bousquet P., «A Statistical and Geometrical Edge Detector for SAR Images», IEEE transactions on geoscience and remote sensing, т. 26, № 6, pp. 764-773, 1988.
160. Cui Z., Quan H., Cao Z., Xu S., Ding C., «SAR target CFAR detection via GPU parallel operation», IEEE journal of selected topics in applied earth observations and remote sensing, т. 11, № 12, pp. 4884-4894, 2018.
161. Chandgude C.P., Chawan P.W., «Ship Detection from SAR Imagery Using CUDA and Performance Analysis of the System», Journal of Engineering Research and Applications, т. 4, № 7, pp. 223-228, 2014.
162. Dai H., Du L., Wang Y., Wang Z., «Modified CFAR Algorithm Based on Object Proposals for Ship Target Detection in SAR Images», IEEE geoscience and remote sensing letters, т. 13, № 12, pp. 1925-1929, 2016.

163. Yu W., Wang Y., Liu H., He J., «Superpixel-based CFAR target detection for high-resolution SAR images», IEEE geoscience and remote sensing letters, т. 13, № 5, pp. 730-734, 2016.
164. Qin X., Zhou S., Zou H., Gao G., «A CFAR Detection Algorithm for Generalized Gamma Distributed Background in High-Resolution SAR Images», IEEE geoscience and remote sensing letters, т. 10, № 4, pp. 806-810, 2013.
165. Gao G., Liu L., Zhao L., Shi G., Kuang G., «An adaptive and fast CFAR algorithm based on automatic censoring for target detection in high-resolution SAR images», IEEE transactions on geoscience and remote sensing, т. 47, № 6, pp. 1685-1697, 2009.
166. S. E.W., «A generalization of the gamma distribution», Annals of Mathematical Statistics, т. 33, № 3, p. 1187–1192, 1962.
167. K. L.M., «Improved SAR target detection via extended fractal features», IEEE transactions on aerospace and electronic systems, т. 37, № 2, pp. 436-451, 2001.
168. Meng W.J., Ju T., Yu Y.H., «CFAR and KPCA for SAR Image Target Detection», в 3rd International Congress on Image and Signal Processing, 2010.
169. «Evaluation of CFAR and Texture Based Target Detection Statistics on SAR Imagery», в Acoustics, Speech, and Signal Processing, 1988 International Conference, 1988.
170. H. H.E., «Long-term storage capacity of reservoirs», Transactions of American Society of Civil Engineers, т. 116, pp. 770-782, 1951.
171. Y. Wang, Q. Yu and W. Yu, «An improved Normalized Cross Correlation algorithm for SAR image registration», в IEEE International Geoscience and Remote Sensing Symposium, 2012.
172. Li Zh., Bethel J., «Image coregistration in SAR interferometry», The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, т. XXXVII, pp. 433-438, 2008.
173. Yague-Martinez N., Eineder M., Brcic R., Breit H., Fritz Th., «TanDEM-X Mission: SAR Image Coregistration Aspects», в EUSAR, 2010.
174. Sansosti Eu, «Geometrical SAR Image Registration», Ieee Transactions On Geoscience And Remote Sensing, т. 44, № 10, pp. 2861-2870, 2006.
175. Yingbing Liu, Yingcheng Zhou, Yongsheng Zhou, Lixiang Ma, Bingnan Wang, and Fan Zhang, «Accelerating SAR Image Registration Using Swarm-Intelligent GPU Parallelization», Ieee Journal Of Selected Topics In Applied Earth Observations And Remote Sensing, т. 13, pp. 5694-5703, 2020.
176. Прэт У., Цифровая обработка изображений, т. 1, Москва: Мир, 1982, p. 495.
177. Masato Iehara, Kazuo Ouchi, Isao Takami, Koichi Morimura, and Shintaro Kumano, «Detection of Ships Using Cross-Correlation of Split-Look SAR Images», в Geoscience and Remote Sensing Symposium, 2001.
178. Р. Г. Магдеев, А. Г. Ташлинский, «Анализ эффективности некоторых методов идентификации объектов на бинарных изображениях», в Всероссийская научно-техническая конференция «Современные проблемы радиоэлектроники», Красноярск, 2014.
179. G. Ch., «Demystifying the Capability of Sublook Correlation Techniques for Vessel Detection in SAR Imagery», IEEE Transactions on Geoscience and Remote Sensing, т. 99, pp. 1-12, 2018.
180. Р. Шовенгердт, Дистанционное зондирование. Модели и методы обработки изображений, М.: Техносфера, 2010, p. 556.



181. R. De Maesschalck, D. Jouan-Rimbaud, and D. L. Massart, «The Mahalanobis distance», *Chemometrics and Intelligent Laboratory Systems*, т. 50, № 1, p. 1–18, 2000.
182. Wang R., Chen J.-W., Wang Y., Jiao L., «SAR Image Change Detection via Spatial Metric Learning With an Improved Mahalanobis Distance», *Geoscience and Remote Sensing Letters*, pp. 1-5, 2019.
183. B. Fiscella, A. Giancaspro, F. Nirchio, P. Pavese & P. Trivero, «Oil spill detection using marine SAR images», *International Journal of Remote Sensing*, т. 21, № 18, p. 3561–3566, 2000.
184. Maillard Ph., Clausi D., «Operational Map-Guided Classification of SAR Sea Ice Imagery», *IEEE Transactions on Geoscience and Remote Sensing*, т. 43, № 12, pp. 2940-2951, 2006.
185. Evelyn F., Hodges J.L., «Discriminatory Analysis. Nonparametric Discrimination: Consistency Properties», *Mathematics*, 1989.
186. S Song, B Xu, J Yang, «SAR Target Recognition via Supervised Discriminative Dictionary Learning and Sparse Representation of the SAR-HOG Feature», *Remote Sensing*, т. 8, 2016.
187. X Yu, Y Li, LC Jiao, «SAR Automatic Target Recognition Based on Classifiers Fusion», в *International Workshop on Multi-Platform/Multi-Sensor Remote Sensing and Mapping*, Xiamen, 2001.
188. C. Cortes, V. Vapnik., «Support-Vector Networks», *Machine Learning*, т. 20, pp. 273-297, 1995.
189. Zhao Q., Principe J.C., «Support Vector Machines For Synthetic Aperture Radar Automatic Target Recognition», 2000.
190. Yan F., Mei W., Chunqin Zh., «SAR Image Target Recognition Based on Hu Invariant Moments and SVM», в *Proceedings of the Fifth International Conference on Information Assurance and Security*, Xi'An, 2009.
191. M. Aizerman, E. Braverman, and L. Rozonoer., «Theoretical foundations of the potential function method in pattern recognition», *Automation and Remote Control*, т. 25, pp. 821-837, 1964.
192. Wenzel, Florian; Galy-Fajou, Theo; Deutsch, Matthäus; Kloft, Marius, «Bayesian Nonlinear Support Vector Machines for Big Data», *Lecture Notes in Computer Science*, p. 307–322, 2017.
193. Mountrakis G., Im J., Ogole C., «Support vector machines in remote sensing», *Journal of Photogrammetry and Remote Sensing*, т. 66, pp. 247-259, 2010.
194. Louis P. Nicoli, Georgios C. Anagnostopoulos, «Shape-based Recognition of Targets in Synthetic Aperture Radar Images using Elliptical Fourier Descriptors», в *Automatic Target Recognition XVIII*, 2008.
195. Pablo Ruiz, Javier Mateos, Gustau Camps-Valls, Rafael Molina, «Bayesian Active Remote Sensing Image Classification», *IEEE Transactions on Geoscience and Remote Sensing*, т. 52, № 4, pp. 2186-2196, 2014.
196. Thiagarajan J.J., Ramamurthy K.N., Knee P., Spanias A., «Sparse Representations for Automatic Target Classification in SAR Images», в *Communications, Control and Signal Processing (ISCCSP)*, 2010.
197. Bingham E., Mannila H., «Random projection in dimensionality reduction: Applications to image and text data», в *Proceedings of the seventh ACM SIGKDD international conference on Knowledge discovery and data mining*, 2001.

198. Mallat S., Zhang Z., «Matching pursuits with time-frequency dictionaries», IEEE Transactions on Signal Processing, т. 41, № 22, pp. 3397-3415, 1994.
199. Liu H., Li Sh., «Decision fusion of sparse representation and support vector machine for SAR image target», Neurocomputing, т. 113, pp. 97-104, 2013.
200. Y. Wei, L. Jiao, F. Liu, S. Yang, Q. Wu, and G. Sanga, «Fast DDL Classification for SAR Images with  $L_{\infty}$  Constraint», IEEE Access, т. 7, p. 68991–69006, 2019.
201. G Dong, G Kuang, «Target Recognition in SAR Images via Classification on Riemannian Manifolds», IEEE Geoscience and remote sensing letters, т. 12, № 1, pp. 199-203, 2015.
202. Z. Zhang, «Joint classification of multiresolution representations with discrimination analysis for SAR ATR», Journal of Electronic Imaging, т. 27, № 4.
203. B. Ding and G. Wen, «Target recognition of SAR images based on multi-resolution representation», Remote Sensing Letters, т. 8, № 11, p. 1006–1014, 2017.
204. J. R. Quinlan, «Induction of Decision Trees», Machine Learning, т. 1, pp. 91-106, 1986.
205. L. Breiman, «Random Forests», Machine Learning, т. 45, № 1, pp. 5-32, 2001.
206. Waske B., Braun M.H., «Classifier ensembles for land cover mapping using multi-temporal SAR imagery», Journal of Photogrammetry and Remote Sensing, т. 64, № 5, pp. 450-457, 2009.
207. Tongyuan Z., Yang W., Dai D., Sun H., «Polarimetric SAR Image Classification Using Multifeatures Combination and Extremely Randomized Clustering Forests», EURASIP journal on advances in signal processing, т. 2, 2010.
208. Loosvelt L., Peters J., Skriver H., Hans L., «Random Forests as a tool for estimating uncertainty at pixel-level in SAR image classification», International Journal of Applied Earth Observation and Geoinformation, т. 19, № 1, p. 173–184, 2012.
209. Zhu Zh., Woodcock C.E., Rogan J., Kellndorfer J., «Assessment of spectral, polarimetric, temporal, and spatial dimensions for urban and peri-urban land cover classification using Landsat and SAR data», Remote Sensing of Environment, т. 117, pp. 72-82, 2011.
210. A Samat, P Du, MHA Baig, Ch Sumit, Ch Liang, «Ensemble Learning with Multiple Classifiers and Polarimetric Features for Polarized SAR Image Classification», Photogrammetric Engineering & Remote Sensing, т. 13, № 3, pp. 239-251, 2014.
211. Topouzelis K., Psyllos A., «Oil spill feature selection and classification using decision tree forest on SAR image data», ISPRS Journal of Photogrammetry and Remote Sensing, т. 68, pp. 135-143, 2012.
212. A Samat, P Du, MHA Baig, Ch Sumit, Ch Liang, «Ensemble Learning with Multiple Classifiers and Polarimetric Features for Polarized SAR Image Classification», Photogrammetric Engineering & Remote Sensing, т. 13, № 3, pp. 239-251, 2014.
213. Xinzheng Zhang, Jianhong Qin, and Guojun Li, «SAR target classification using Bayesian compressive sensing with scattering centers features», Progress In Electromagnetics Research, т. 136, p. 385–407, 2013.
214. L. C. Potter and R. L. Moses, «Attributed scattering centers for SAR ATR», IEEE Trans Image Process, т. 6, № 1, pp. 79-91, 1997.
215. X. Zhang, «Noise-robust target recognition of SAR images based on attribute scattering center matching», Remote Sensing Letters, т. 10, № 2, pp. 186-194, 2019.
216. T. Li and L. Du, «SAR Automatic Target Recognition Based on Attribute Scattering Center Model and Discriminative Dictionary Learning», IEEE Sensors Journal, т. 19, № 12, p. 4598–4611, 2019.

217. B. Ding, G. Wen, X. Huang, C. Ma, and X. Yang, «Data Augmentation by Multilevel Reconstruction Using Attributed Scattering Center for SAR Target Recognition», *IEEE Geoscience and Remote Sensing Letters*, т. 14, № 6, p. 979–983, 2017.
218. H. W. Kuhn, «The Hungarian Method for the assignment problem», *Naval Research Logistics Quarterly*, т. 2, pp. 83–97, 1955.
219. Ding B., Wen G., Huang X., Ma C., Yang X. «Target Recognition in Synthetic Aperture Radar Images via Matching of Attributed Scattering Centers», *IEEE Journal of selected topics in applied Earth observations and remote sensing*, т. 10, № 7, pp. 3334–3347, 2017.
220. Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard and L. D. Jackel, «Backpropagation Applied to Handwritten Zip Code Recognition», *Neural Computation*, т. 1, № 4, pp. 541–551, 1989.
221. Z. Tian, L. Wang, R. Zhan, J. Hu, and J. Zhang, «Classification via weighted kernel CNN: application to SAR target recognition», *International Journal of Remote Sensing*, т. 39, № 23, p. 9249–9268, 2018.
222. Г. А. И., Синтез многослойных систем распознавания образов, М.: Энергия, 1974.
223. Bruzzone L., Marconcini M., Wegmuller U., Wiesmann A. «An Advanced System for the Automatic Classification of Multitemporal SAR Images», *IEEE Transactions on Geoscience and Remote Sensing*, т. 42, № 6, pp. 1321–1334, 2004.
224. F. Gao, T. Huang, J. Sun, J. Wang, A. Hussain, and E. Yang, «A New Algorithm for SAR Image Target Recognition Based on an Improved Deep Convolutional Neural Network», *Cognitive computing*, т. 11, № 6, p. 809–824, 2019.
225. H. Wang, S. Chen, F. Xu, and Y.-Q. Jin, «Application of deep-learning algorithms to MSTAR data», в *IEEE International Geoscience and Remote Sensing Symposium*, 2015.
226. Y. Kwak, W.-J. Song, and S.-E. Kim, «peckle-Noise-Invariant Convolutional Neural Network for SAR Target Recognition», *IEEE Geoscience and Remote Sensing Letters*, pp. 1–5, 2018.
227. R. Min, H. Lan, Z. Cao, and Z. Cui, «A Gradually Distilled CNN for SAR Target Recognition», *IEEE Access*, т. 7, p. 42190–42200, 2019.
228. J. Wang, T. Zheng, P. Lei, and X. Bai, «Ground Target Classification in Noisy SAR Images Using Convolutional Neural Networks», *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, т. 11, № 11, p. 4180–4192, 2018.
229. R. Shang, J. Wang, L. Jiao, R. Stolkin, B. Hou, and Y. Li, «SAR Targets Classification Based on Deep Memory Convolution Neural Networks and Transfer Parameters», *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, т. 11, № 8, p. 2834–2846, 2018.
230. He Zh., Lu J., Kuang G., «A Fast SAR Target Recognition Approach Using PCA Features», в *Fourth International Conference on Image and Graphics*, 2007.
231. Yue Zh., Fei G., Xiong Q., Wang J., «A Novel Semi-Supervised Convolutional Neural Network Method for Synthetic Aperture Radar Image Recognition», *Cognitive Computation*, т. 13, № 10, 2021.
232. M. Amrani and F. Jiang, «Deep feature extraction and combination for synthetic aperture radar target classification», *Journal of Applied Remote Sensing*, т. 11, № 4, 2017.
233. Duan Y., Liu F., Jiao L., Zhao P., «SAR Image Segmentation Based on Convolutional-wavelet Neural Network and Markov Random Field», *Pattern Recognition*, т. 64, 2016.
234. O. Kechagias-Stamatis, N. Aouf, and C. Belloni, «SAR Automatic Target Recognition based on Convolutional Neural Networks», в *International Conference on Radar Systems*, 2017.

235. Gao Fei, Huang Teng, Jun Wang, Jinping Sun, «Combining Deep Convolutional Neural Network and SVM to SAR Image Target Recognition», в IEEE Cyber, Physical and Social Computing, 2017.
236. S. A. Wagner, «SAR ATR by a combination of convolutional neural network and support vector machines», IEEE Transactions on Aerospace and Electronic Systems, т. 52, № 6, p. 2861–2872, 2016.
237. Lv J., Liu Y., «Data Augmentation Based on Attributed Scattering Centers to Train Robust CNN for SAR ATR», IEEE Access, т. 7, 2019.
238. F. Zhang, Y. Liu, Y. Zhou, Q. Yin, and H. C. Li, «A lossless lightweight CNN design for SAR target recognition», Remote Sensing Letters, т. 11, № 5, p. 485–494, 2020.
239. C. Zhong, X. Mu, X. He, J. Wang, and M. Zhu, «SAR Target Image Classification Based on Transfer Learning and Model Compression», IEEE Geoscience and Remote Sensing Letters, 2018.
240. Heng-Chao Lia, Gang Yanga, Wen Yangb, Qian Duc, William J. Emery, «ix factorization network with semisupervised learning for SAR image change detection», ISPRS Journal of Photogrammetry and Remote Sensing, т. 160, p. 167–179, 2020.
241. Y. Yan, «Convolutional neural networks based on augmented training samples for synthetic aperture radar target recognition», Journal of Electronic Imaging, т. 27, № 2, 2018.
242. A. Krizhevsky, I. Sutskever, and G. Hinton, «Imagenet classification with deep convolutional neural networks», in Advances in neural information processing systems», Advances in neural information processing systems, p. 1097–1105, 2012.
243. K. Simonyan and A. Zisserman, «Very Deep Convolutional Networks for Large-Scale Image Recognition», Information and Software Technology, т. 51, № 4, p. 769–784, 2014.
244. O. Kechagias-Stamatis, «Target recognition for synthetic aperture radar imagery based on convolutional neural network feature fusion», Journal of Applied Remote Sensing, т. 12, № 4, 2018.
245. J. Deng, W. Dong, R. Socher, L.-J. Li, Kai Li, and Li Fei-Fei, «ImageNet: A large-scale hierarchical image database», в IEEE Conference on Computer Vision and Pattern Recognition, 2009.
246. Z. Cui, M. Zhang, Z. Cao, and C. Cao, «Image Data Augmentation for SAR Sensor via Generative Adversarial Nets», IEEE Access, т. 7, p. 42255–42268, 2019.
247. Y. Sun, Y. Wang, H. Liu, N. Wang, and J. Wang, «SAR Target Recognition With Limited Training Data Based on Angular Rotation Generative Network», IEEE Geoscience and Remote Sensing Letters, 2019.
248. Fei Gao, Fei Ma, Jun Wang, Jinping Sun, Erfu Yang, Huiyu Zhou, «Semi-Supervised Generative Adversarial Nets with Multiple Generators for SAR Image Recognition», Sensors, т. 18, № 8, 2018.
249. Planinšič P., Gleich D. «Temporal Change Detection in SAR Images Using Log Cumulants and Stacked Autoencoder», IEEE geoscience and remote sensing letters, т. 15, № 2, pp. 297–301, 2018.
250. Lv N., Chen C., Qiu T., Sangaiah A.K., «Deep Learning and Superpixel Feature Extraction Based on Contractive Autoencoder for Change Detection in SAR Images», IEEE Transactions on Industrial Informatics, т. 14, № 12, pp. 5530–5538, 2018.
251. Gong M., Yang H., Zhang P., «Feature learning and change feature classification based on deep learning for ternary change detection in SAR images», ISPRS Journal of Photogrammetry and Remote Sensing, т. 129, pp. 212–225, 2017.

252. De S., Pirrone D., Bovolo F., Bruzzone L., «A novel change detection framework based on deep learning for the analysis of multi-temporal polarimetric SAR images».
253. Luo B., Hu C., Su X., Wang Y., «Differentially Deep Subspace Representation for Unsupervised Change Detection of SAR Images», *Remote Sensing*, т. 11, № 23, 2019.
254. Geng J., Wang H., Fan J., Ma X., «Change Detection of SAR Images Based on Supervised Contractive Autoencoders and Fuzzy Clustering».
255. Parikh H., Patel S., Patel V., «Classification of SAR and PolSAR images using deep learning: a review», *International Journal of Image and Data Fusion*.
256. X. Huang, X. Nie, W. Wu, H. Qiao, and B. Zhang, «SAR target configuration recognition based on the biologically inspired model», *Neurocomputing*, т. 234, p. 185–191, 2017.
257. Liu F., Jiao L., Hou B., Yang S., «POL-SAR Image Classification Based on Wishart DBN and Local Spatial Information», *IEEE transactions on geoscience and remote sensing*, т. 54, № 6, pp. 3293–3308, 2016.
258. Liu J., Gong M., Zhao J., Li H., Jiao L., «Difference representation learning using stacked restricted Boltzmann machines for change detection in SAR images», *Soft Computing*, т. 20, № 12.
259. Samadi F., Akbarizadeh G., Kaabi H., «Change detection in SAR images using deep belief network: a new training approach based on morphological images», *IET Image Processing*, т. 13, № 12, pp. 2255–2264, 2019.
260. Tanase R., Datcu M., Raducanu D., «A Convolutional deep belief network for polarimetric SAR data feature extraction», в *IEEE International Geoscience and Remote Sensing Symposium*, 2016.
261. Attioui S., Najah S., «Unsupervised change detection method in SAR images based on deep belief network using an improved fuzzy C-means clustering algorithm», *IET Image Processing*, т. 15, p. 974–982, 2021.
262. Chen, S., et al., «Target classification using the deep convolutional networks for sar images», *Remote Sensing*, т. 54, № 8, p. 4806–4817, 2016.
263. Zhao Z., Jiao L., Zhao J., Gu J., Zhao J., «Discriminant deep belief network for high-resolution SAR image classification», *Pattern Recognition*, т. 61, pp. 686–701, 2017.
264. J. Geng, H. Wang, J. Fan and X. Ma, «SAR Image Classification via Deep Recurrent Encoding Neural Networks», *IEEE Transactions on Geoscience and Remote Sensing*, т. 56, № 4, pp. 2255–2269, 2018.
265. L. Wang, X. Xu, H. Dong, R. Gui, R. Yang and F. Pu, «Exploring Convolutional Lstm for Polsar Image Classification», в *IGARSS 2018 – 2018 IEEE International Geoscience and Remote Sensing Symposium*, Valencia, 2018.
266. Castro J.B., Feitosa R.Q., Happ P.N., «An hybrid recurrent convolutional neural network for crop type recognition based on multitemporal SAR image sequences», в *IGARSS 2018 – 2018 IEEE International Geoscience and Remote Sensing Symposium*, 2018.
267. Kazemi S., Yonel B., Yazici B., «Deep Learning for Direct Automatic Target Recognition from SAR Data», в *2019 IEEE Radar Conference (RadarConf)*, 2019.
268. Wei G., Qingwen Q., Lili J., Ping Z., «A New Method of SAR Image Target Recognition based on AdaBoost Algorithm», в *IGARSS 2008 – 2008 IEEE International Geoscience and Remote Sensing Symposium*, 2008.
269. Chen K., Li Y., Xu X., Li Y., «A modified AdaBoost algorithm with new discrimination features for high-resolution SAR targets recognition», *IEICE Transactions on Information and Systems*, т. E98.D, № 10, pp. 1871–1874, 2015.



270. Ji X.X., Zhang G., «SAR Image Target Recognition with Increasing Sub-classifier Diversity Based on Adaptive Boosting», в 2014 Sixth International Conference on Intelligent Human-Machine Systems and Cybernetics, 2014.
271. Min R., Quan H., Cui Z., Cao Z., Pi Y., «SAR Target Detection Using AdaBoost via GPU Acceleration», в IEEE International Geoscience and Remote Sensing Symposium, 2019.
272. Wen X.B., Zhang H., Jiang Z.T., «Multiscale Unsupervised Segmentation of SAR Imagery Using the Genetic Algorithm», Sensors, т. 8, № 3, pp. 1704-1711, 2008.
273. Bhanu B., Lin Y., «Genetic algorithm based feature selection for target detection in SAR images», Image and Vision Computing, т. 21, № 7, pp. 591-608, 2003.
274. С. О.П., «Применение генетических алгоритмов для распознавания изображений», Искусственный интеллект, № 4, pp. 516-520, 2002.
275. Hong-lei Z., Zhu-lin L., Yan W., «Road recognition in high resolution SAR image based on genetic algorithm», 2006.
276. Park J.I., Park S.H., Kim K.T., «New Discrimination Features for SAR Automatic Target Recognition», IEEE geoscience and remote sensing letters, т. 10, № 3, pp. 476-480, 2013.
277. Yang S., Wang M., Jiao L., «Radar target recognition using contourlet packet transform and neural network approach», Signal Processing, т. 89, № 4, pp. 394-409, 2009.
278. С. Д., Алгоритмы эволюционной оптимизации, М.: ДМК Пресс, 2020, p. 940.

---

## 2. РАДИОЛОКАЦИОННЫЕ СИСТЕМЫ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ

За свою шестидесятилетнюю историю мониторинг земной поверхности в радиодиапазоне осуществлялся с использованием более чем сотни авиационных и космических платформ [1]. И если изначально это были устройства, основанные исключительно на принципах бокового обзора, то с течением времени методы совершенствовались, аппараты начали использовать когерентное накопление сигнала и технологию синтеза апертуры (РСА). Постепенно накапливался опыт обработки получаемых данных, а вместе с ним приходило осознание возможных направлений дальнейшего развития и улучшения качества РЛИ. С течением времени улучшалось пространственное разрешение, появились сенсоры, учитывающие поляризацию электромагнитных волн. Менялись и цели использования радиолокационных систем наблюдения — от военных разведывательных задач осуществлялся постепенный переход к гражданским миссиям, таким как мониторинг ледовой обстановки, наблюдения за природными и антропогенными объектами, прогнозирование чрезвычайных ситуаций и оценка последствий их ущерба и многое другое. Использование принципов интерферометрической обработки данных, полученных с различных витков орбиты, привело к появлению быстрого, практически полностью автоматизированного и сравнительно недорогого метода построения трехмерных моделей рельефа, создавая альтернативу фотограмметрической стереообработке изображений оптического диапазона. С постепенным повышением пространственного разрешения круг потенциальных гражданских задач расширялся, что стимулировало запуск коммерческих космических систем дистанционного зондирования Земли (ДЗЗ). В настоящем разделе приведены наиболее распространенные коммерческие спутники ДЗЗ с указанием основных параметров и решаемых с их применением задач.

### 2.1. ALOS

ALOS (Advanced Land Observation Satellite) — серия японских спутников ДЗЗ [2], включающая два космических аппарата, владельцем которых является Японское аэрокосмическое агентство JAXA. Первый спутник ALOS (ALOS-1) был запущен в январе 2006 года и прослужил в общей сложности более 5 лет. Второй аппарат серии, ALOS-2, был выведен на орбиту в мае 2014 года и продолжил миссию своего предшественника. На сегодняшний день ALOS-2 — один из немногих коммерческих спутников ДЗЗ (наряду с SAOCOM-1A и SAOCOM-1B [3]), поставляющий радиолокационные изображения в L-диапазоне, что делает его незаменимым при решении ряда специфических задач.

Аппарат ALOS располагался на солнечно-синхронной орбите<sup>1</sup> высотой 692 км и наклонением<sup>2</sup> 93,2°. В основные задачи спутниковой системы входили круглосуточный

---

<sup>1</sup> Солнечно-синхронная орбита — геоцентрическая орбита с такими параметрами, что объект, находящийся на ней, проходит над любой точкой земной поверхности приблизительно в одно и то же местное солнечное время [4].

<sup>2</sup> Наклонение — один из кеплеровских шести элементов орбиты, угол между плоскостью орбиты и базовой плоскостью [4]. Для искусственных спутников Земли в качестве базовой используется плоскость эклиптики.

и всепогодный мониторинг земной поверхности и океанов, создание и обновление топографических карт масштаба 1:25000 и мельче, контроль использования природных ресурсов, создание высокоточных цифровых моделей рельефа, мониторинг природных катастроф, а также решение различных научных и прикладных задач. В полезную нагрузку ALOS входило три сенсора: AVNIR-2 (Advanced Visible and Near Infrared Radiometr), PRISM (Panchromatic Remote-sensing Instrument of Stereo Mapping) и PALSAR (Phased Array L-band Synthetic Aperture Radar). AVNIR-2 представлял собой камеру, осуществлявшую съемку поверхности с полосой захвата до 70 км и пространственным разрешением до 10 м, обеспечивая получение многозональных космоснимков в четырех спектральных диапазонах (синий, зеленый, красный и ближний инфракрасный каналы). PRISM – картографическая стереокамера для формирования триплетов изображений в оптическом диапазоне, состоял из трёх панхроматических камер, обеспечивающих пространственное разрешение до 2,5 м. Наконец, PALSAR представлял собой РСА-датчик L-диапазона (рабочая длина волны 23 см), обеспечивающий разрешение на местности до 7 м. Схема космического аппарата с основным оборудованием приведена на рис. 2.1 [5].




Рис. 2.1. Схематическое изображение космического аппарата ALOS

Рассмотрим характеристики сенсора PALSAR более подробно. Сенсор PALSAR изменял угол визирования от 8 до 60° относительно направления в надир<sup>3</sup> благодаря технологии фазированных антенных решеток с 80 модулями приема/передачи [6]. PALSAR поддерживал съемку в трех режимах работы – детальном (маршрутном) режиме (Fine), режиме сканирования (ScanSAR) и поляризационном режиме (Polarimetric). Детальный режим использовался наиболее часто, позволяя получать изображения с пространственным разрешением до 7 м, что на время начала работы спутника являлось рекордом среди РСА-систем. Именно этот режим использовался для получения данных для последующей интерферометрической обработки. Детальный режим разделялся на два подрежима, в первом из которых (Fine 1)

<sup>3</sup> Надир – направление, совпадающее действия силы гравитации для конкретной точки [7].

формировались высокодетальные изображения в режиме одиночной поляризации (HH либо VV), во втором (Fine 2) – изображения более низкого пространственного разрешения в режиме двойной поляризации (HH + HV либо VV + VH). С помощью режима ScanSAR осуществлялось наблюдение местности с полосой захвата от 250 до 350 км с низким пространственным разрешением, он предназначался для глобального природного мониторинга. В этом режиме была возможна реализация только одиночной поляризации (HH либо VV). Поляризационный режим на момент разработки аппарата ALOS являлся экспериментальным и использовал как вертикальную, так и горизонтальную поляризации электромагнитных волн, обеспечивая полный поляризационный базис (HH + HV + VH + VV). Формат получаемых данных в зависимости от уровня обработки – CEOS/GeoTIFF, радиометрическое разрешение<sup>4</sup> составляло 5 бит, периодичность съемки – 46 дней. Основные параметры приведенных режимов сенсора PALSAR приведены в табл. 2.1 [2].

Таблица 2.1

Основные режимы работы сенсора PALSAR спутника ALOS

| Режим        | Пространственное разрешение <sup>5</sup> , м | Полоса обзора <sup>6</sup> , км | Угол визирования, ° |
|--------------|--|---------------------------------|---------------------|
| Fine 1       | 7  | 70                              | 8–60                |
| Fine 2       | 14   | 70                              | 8–60                |
| ScanSAR      | 100  | 350                             | 18–43               |
| Polarimetric | 24   | 65                              | 8–30                |

На рис. 2.2 представлен фрагмент изображения, полученного с помощью космического аппарата ALOS сенсором PALSAR в детальном режиме съемки Fine 1.

Спутник ALOS-2 выведен на солнечно-синхронную орбиту высотой 638 км и наклоном 97,9°. В отличие от своего предшественника, ALOS-2 не оснащен оптическими камерами наблюдения, представляя собой спутник ДЗЗ, выполняющий съемку исключительно в радиодиапазоне. На аппарате установлен PCA-датчик PALSAR-2, являющийся усовершенствованной версией сенсора PALSAR, а также система автоматической идентификации морских судов SPAISE2 и инфракрасная камера CIRC [36]. PCA-датчик ALOS-2 осуществляет наблюдения в трех режимах: сверхвысокого разрешения (SpotLight), высокого разрешения (StripMap), а также в сканирующем режиме (ScanSAR).

В режиме SpotLight, представляющем прожекторный режим, осуществляется съемка с пространственным разрешением до 1 м в режиме одиночной поляризации (HH, HV либо VV). StripMap является основным рабочим режимом спутника и разделяется на три подрежима: UltraFine, High Sensitive и Fine. Режим UltraFine обеспечивает съемку местности с пространственным разрешением до 3 м как в режиме одиночной (HH, HV либо VV), так и в режиме двойной поляризации (HH + HV либо VV + VH).

<sup>4</sup> Радиометрическое разрешение – количество градаций значений оттенков серого, соответствующих переходу от яркости абсолютно «черного» к абсолютно «белому», и выражается в количестве бит на пиксел изображения [8].

<sup>5</sup> Здесь и далее имеется в виду наименьший интервал пространственной дискретизации в направлении азимута.

<sup>6</sup> Здесь и далее имеется в виду наибольшее значение размеров местности под пятном засветки в направлении дальности.



В режиме High Sensitive возможно получение изображений земной поверхности с пространственным разрешением до 6 м в режиме одиночной (HH, HV либо VV) и двойной (HH + HV либо VV + VH) поляризации, а также в полном поляризационном базисе (HH + HV + VH + VV), причем в последнем случае область охвата снимка окажется меньше. Аналогично, в режиме Fine возможно получить изображение земной поверхности с пространственным разрешением до 10 м во всех трех режимах поляризации, однако для полного поляризационного базиса охват местности будет меньше. Режим ScanSAR предназначен для получения изображений в низком пространственном разрешении при максимально возможном охвате местности. Различают два подрежима: стандартный (Normal) и расширенный (Wide). Для обоих режимов возможна как одиночная (HH, HV либо VV), так и двойная (HH + HV либо VV + VH) поляризация. Основные технические характеристики датчика PALSAR-2 приведены в табл. 2.2 [9].



Рис. 2.2. Фрагмент изображения, полученного с помощью датчика PALSAR. Территория села Ачхой-Мартан, Чеченская республика, 2010 год [8]

На рис. 2.3 представлен фрагмент изображения, полученного с помощью датчика PALSAR-2, режим съемки Fine.

В конце 2020 года на орбиту планируется вывести следующий аппарат миссии — ALOS-3 [10]. Спутник будет оснащен оборудованием, предназначенным для мониторинга исключительно в оптическом диапазоне: стереокамера PRISM-2, обеспечивающая высокодетальную панхроматическую съемку местности с пространственным разрешением 0,8 м и шириной полосы обзора 50 км; мультиспектральный сканер HISUI (Hyperspectral Imager Suite), формирующий изображения в пяти спектральных диапазонах (видимые и ближний инфракрасный) с пространственным разрешением до 5 м.



Таблица 2.2

Основные режимы работы сенсора PALSAR-2 спутника ALOS-2

| Режим                     | Пространственное разрешение, м | Полоса обзора, км     | Угол визирования, ° |
|---------------------------|--------------------------------|-----------------------|---------------------|
| SpotLight                 | 1                              | 25                    | 8–70                |
| StripMap (UltraFine)      | 3                              | 50                    | 8–70                |
| StripMap (High sensitive) | 6                              | 50<br>40 <sup>7</sup> | 8–70<br>20–40       |
| StripMap (Fine)           | 10                             | 70<br>30 <sup>8</sup> | 8–70<br>23,7        |
| ScanSAR (N)               | 100                            | 350                   | 8–70                |
| ScanSAR (W)               | 60                             | 490                   | 8–70                |




Рис. 2.3. Фрагмент изображения, полученного с помощью датчика PALSAR-2.  
Вулкан Мерапи, остров Ява, Индонезия, 2014 год [9]

## 2.2. COSMO-SkyMed

COSMO-SkyMed (Constellation of small Satellites for the Mediterranean basin Observation, сокращенное название COS) — группировка четырех идентичных итальянских спутников, предназначенных для всепогодного мониторинга земной

<sup>7</sup> При съемке в полном поляризационном базисе (HH + HV + VH + VV).

<sup>8</sup> При съемке в полном поляризационном базисе (HH + HV + VH + VV).

поверхности в военных и научных целях [11]. Отдельные аппараты принято обозначать как COSMO-SkyMed-1, -2, -3 и -4. В период с июня 2007 по ноябрь 2010 все четыре спутника были выведены на общую солнечно-синхронную орбиту высотой 619 км и наклонением  $97,9^\circ$ . Среди основных гражданских задач группировки COSMO-SkyMed можно выделить следующие: создание и обновление топографических карт масштаба 1:10 000 и мельче, получение высокоточных цифровых моделей рельефа<sup>9</sup> (ЦМР), непрерывный мониторинг природных и антропогенных объектов, прогнозирование землетрясений и извержений вулканов.

Все аппараты созвездия в каждый момент находятся в одной плоскости, при этом возможны два варианта конфигурации спутников на орбите: номинальный и интерференционный [12]. В номинальном режиме все аппараты расположены на равных угловых расстояниях, составляющих  $90^\circ$  (рис. 2.4, а).



Рис. 2.4. Конфигурация аппаратов группировки COSMO-SkyMed (обозначены как S-1–S-4): а – номинальный режим; б – интерференционный режим, линия В – интерферометрический базис съемки. ♈ – восходящий узел орбиты<sup>10</sup>, ♏ – нисходящий узел орбиты<sup>11</sup>

Благодаря такой конфигурации, наблюдения за интересующей областью могут быть проведены до нескольких раз в день, что даёт возможность быстрого реагирования в случаях чрезвычайных ситуаций. Интерферометрический режим используется для получения трехмерных моделей местности, в этом случае два аппарата группировки располагаются на достаточно близком угловом расстоянии (рис. 2.4, б). В такой конфигурации осуществляется съемка одной и той же территории с двух спутников с несколько различающихся ракурсов, при этом расстояние между орбитами спутников выступает в роли интерферометрического базиса. Следует иметь в виду, что

<sup>9</sup> Цифровая модель рельефа – цифровое представление земной поверхности как непрерывного явления, описывающее ее с определенной точностью. Для хранения цифровых моделей рельефа могут использоваться как растровые форматы, в этом случае представление является регулярным, так и векторные, тогда представление будет нерегулярным. Точность ЦМР принято характеризовать двумя параметрами: точность плановой привязки, показывающей, насколько хорошо ЦМР соответствует положению в определенной геодезической системе координат, и точность по высоте, характеризующую степень соответствия полученного продукта реальной картине местности.

<sup>10</sup> Восходящий узел орбиты (северный) – точка, в которой движущееся по орбите тело пересекает условную плоскость в северном направлении [13].

<sup>11</sup> Нисходящий узел орбиты (южный) – точка, в которой движущееся по орбите тело пересекает условную плоскость в южном направлении [13].

из-за различных погрешностей (запуск, движение в условиях атмосферы Земли, управление космическим аппаратом и т. д.) орбиты спутников совпадают только в некоторой степени, реально расстояние между ними составляет от сотен метров до единиц километров. Это расстояние между орбитами и образует интерферометрический базис, что позволяет использовать получаемые данные в задачах измерения рельефа. Последующая обработка полученных изображений позволяет восстановить трехмерную картину местности, а также исследовать ее изменения. Для ЦМР, получаемых с использованием данных аппаратов COSMO-SkyMed, относительная точность по высоте составляет от 3,8 до 76 м в зависимости от режима съемки.

Каждый из спутников COSMO-SkyMed оснащен РСА-датчиком X-диапазона (рабочая длина волны 3,1 см), сам сенсор представляет собой фазированную решётку размерами 1,4×5,7 м [14]. Различают три основных режима работы: сверхвысокого разрешения (SpotLight), высокого разрешения (StripMap) и среднего/низкого разрешения (ScanSAR). Режим SpotLight (прожекторный режим) предназначен для выполнения съемки сверхвысокого пространственного разрешения. В нем различают два подрежима: SpotLight-1, который используется только решения для военных задач, и SpotLight-2, применяющийся в гражданских миссиях.

Съемка осуществляется в одиночной поляризации (НН либо VV). Для режима StripMap (маршрутный режим) возможны две модификации – Himage, обеспечивающий съемку в более высокой детализации, и PingPong, с помощью которого формируются изображения с пространственным разрешением до 20 м. Для подрежима Himage возможна только одиночная поляризация (НН, НV, VН либо VV), для PingPong – двойная (НН + VV, НН/НV либо VV + VН). Наконец, режим ScanSAR предназначен для получения изображений местности с максимально широким пространственным охватом. В нем также различают два подрежима – Wide и Huge с охватом местности 100 и 200 км соответственно. В режиме ScanSAR (сканирующий режим) возможна только одиночная поляризация (НН, НV, VН либо VV). Радиометрическое разрешение данных составляет 8 бит, скорость передачи данных на наземный сегмент – 310 Мбит/с, периодичность съемки в номинальной конфигурации – 10 часов. Основные параметры различных режимов работы сенсоров приведены в табл. 2.3.

Таблица 2.3

Режимы работы РСА-датчиков спутников группировки COSMO-SkyMed

| Режим               | Пространственное разрешение, м | Полоса обзора, км | Угол визирования, ° |
|---------------------|--------------------------------|-------------------|---------------------|
| SpotLight-2         | 1                              | 10                | 20–60               |
| StripMap (Himage)   | 5                              | 40                | 18–60               |
| StripMap (PingPong) | 20                             | 30                | 19–59               |
| ScanSAR (Wide)      | 30                             | 100               | 18–60               |
| ScanSAR (Huge)      | 100                            | 200               | 18–60               |

На рис. 2.5 приведен фрагмент изображения, полученного одним из аппаратов группировки COSMO-SkyMed в режиме высокого разрешения.






Рис. 2.5. Фрагмент изображения, полученного с помощью спутника COSMO-SkyMed (режим StripMap). Вершины горы Этна, Сицилия [12]

Для задач дополнения и постепенного замещения спутников группировки COSMO-SkyMed в настоящее время Итальянское космическое агентство ведет разработку аппаратов серии COSMO-SkyMed второго поколения – CSG [17]. Основное отличие аппаратов нового поколения заключается в том, что группировка будет состоять только из двух спутников – CSG-1 и -2, целевая аппаратура которых будет представлять собой улучшенные версии сенсоров спутников первого поколения. Орбита аппаратов второго поколения будет полностью совпадать с уже имеющейся.

### 2.3. ERS

ERS (European Remote-Sensing Satellite) – серия из двух космических аппаратов Европейского космического агентства, предназначенных для мониторинга земной поверхности и атмосферы [15]. Спутник ERS-1 был выведен на солнечно-синхронную орбиту в июле 1991 года, прослужив в общей сложности почти 9 лет. Высота орбиты составляла 758 км, наклонение –  $98,5^\circ$ . Несмотря на то, что изначально бортовая аппаратура предназначалась для изучения атмосферы и водной поверхности, спустя некоторое время после запуска ERS-1 продемонстрировал свою эффективность в решении задач геологии, картографии и мониторинга растительного покрова. Поэтому

через три года после запуска ERS-1, в апреле 1995 года на ту же самую орбиту был запущен второй спутник серии ERS-2. По большей части этот аппарат был идентичен ERS-1, за исключением одного нового сенсора. Эксплуатация ERS-2 завершилась в сентябре 2011 года.

Рассмотрим более подробно инструменты аппарата ERS-1 [16]. Высотометр RA (Radar Altimeter) представлял собой одночастотный направленный в надир радиолокатор Ku-диапазона и предназначался для высокоточного измерения уровня морей и океанов, различных параметров ледяного покрова, а также скорости океанических ветров. Прибор ATSR-1 (Along-Track Scanning Radiometer) состоял из четырехканального инфракрасного радиометра и микроволнового излучателя, применялся для измерения температуры водной поверхности, а также температуры и влажности облаков. Наконец, датчик AMI представлял собой PCA-радиолокатор C-диапазона (рабочая длина волны 5,66 см) и предназначался для всепогодного мониторинга земной поверхности, обеспечивая формирование РЛИ с пространственным разрешением до 10 м.

Спутник ERS-2 был оснащен тем же самым оборудованием, что и ERS-1, однако также включал дополнительный инструмент — спектрометр ультрафиолетового и видимого диапазона GOME (Global Ozone Monitoring Experiment) [17], предназначавшийся для глобального мониторинга озонового слоя. Кроме того, совместное использование данных с обоих спутников позволяло решать задачи по обнаружению подвижек рельефа, обеспечивая субмиллиметровую точность согласно спецификации. Основная целевая аппаратура спутника ERS-2 представлена на рис. 2.6.

Рассмотрим подробнее инструмент AMI [16]. Фактически он представлял собой два независимых датчика: собственно, PCA-сенсор (AMI-SAR), выполнявший работу в двух режимах наблюдения — режиме изображения (Imaging mode) и волновом режиме (Wave Mode), а также радиолокационный рефлектометр (AMI-SCAT), предназначавшийся для сбора информации о скорости и направления ветров. Режим изображения использовался для формирования РЛИ высокого разрешения (от 10 до 30 м) и предоставлял собой традиционную маршрутную съемку. На рис. 2.7 приведен фрагмент изображения, полученного в данном режиме. Волновой режим датчика предназначался для получения двумерного изображения спектра морских и океанических волн. В этом режиме сенсор осуществлял запись участков поверхности в рамках ширины кадра (5×5 км) с интервалом повторения каждые 200–300 км. Спектральное представление позволяло напрямую извлечь данные о размере волн и их ориентации в пространстве. Первоначально полученные данные использовались при прогнозировании погоды, однако, впоследствии оказались также применимы для обнаружения таких явлений, таких как пленки на поверхности, приповерхностные течения и лед. Размер антенны AMI-SAR составлял 10×1 м, радиометрическое разрешение данных — 5 бит. Оба режима сенсора использовали только одиночный тип поляризации (VV).

Прибор AMI-SCAT включал три независимые боковые антенны для измерения скорости приповерхностных морских и океанических ветров (рис. 2.8). Принцип работы заключался в фиксации изменений ЭПР водной поверхности, обусловленной появлением ряби определенного типа при наличии ветров. Результаты съемки использовались в качестве опорных модельных данных при решении задач прогнозирования климатических изменений. Точность данных составляла 20° по направлению скорости и 2 м/с по величине скорости. Пространственное разрешение данных SCAT было достаточно низким и составляло 50 км. Следует отметить, что датчики SCAT и SAR не могли работать одновременно. Основные параметры режимов съемки представлены в табл. 2.4.






Рис. 2.6. Схематическое изображение космического аппарата ERS-2 [18]

Таблица 2.4  
Основные режимы работы инструмента AMI спутников ERS

| Режим        | Пространственное разрешение, м | Полоса обзора, км | Угол визирования, ° |
|--------------|--------------------------------|-------------------|---------------------|
| Imaging mode | 10                             | 100               | 23 <sup>12</sup>    |
| Wave Mode    | 30                             | 5                 | 23                  |
| SCAT         | 5000                           | 500               | 18–47               |

Несмотря на то, что спутники ERS-1 и ERS-2 в настоящий момент прекратили свою деятельность, полученные с их помощью данные до сих пор находят широкое применение в различных научных и прикладных областях деятельности. Можно

<sup>12</sup> После апреля 1992 спутник ERS-1 перешел в режим «разворотов и наклонов» (RTM Roll-tilt mode), что позволило увеличить угол визирования до 35°.

сказать, что миссия ERS положила начало регулярным наблюдениям поверхности Земли из космоса в радиодиапазоне в интересах Европейского космического агентства. Нарботки, использованные при проектировании аппаратов серии ERS, а также анализ эксплуатационного опыта легли в основу разработки последующих радиолокационных миссий, предназначенных для мониторинга территории Европы.




Рис. 2.7. Фрагмент изображения, полученного с помощью сенсора AMI спутника ERS-2 (режим Imaging mode). Атлантическое побережье северной Коста-Рики и южной Никарагуа [17]

## 2.4. Envisat

Envisat — спутник Европейского космического агентства, предназначенный для исследования Земли из космоса [19]. По своей сути Envisat являлся приемником миссии спутников серии ERS. Он выведен на солнечно-синхронную полярную орбиту в марте 2002 года, апоцентр<sup>13</sup> орбиты составлял 791 км, перицентр<sup>14</sup> — 785 км,

<sup>13</sup> Апоцентр — наиболее удаленная от центрального тела точка орбиты небесного тела [4].

<sup>14</sup> Перицентр — ближайшая к центральному телу точка орбиты небесного тела [4].



наклонение  $98,6^\circ$ . Основная миссия аппарата состояла в обеспечении непрерывности полетов европейских спутников ДЗЗ, предоставляя дополнительные данные для выполнения экологических исследований, в частности, исследования химического состава и динамики атмосферы, мониторинга гидрографической обстановки (температура и цвет воды, волны, гидрология), мониторинг сельского и лесного хозяйства, изучение снежных и ледовых покровов, а также создание цифровых моделей рельефа (в тандеме с данными, получаемыми с помощью аппаратов ERS-1, -2) и картографической продукции. В апреле 2012 года была потеряна связь с космическим аппаратом, после чего Европейское космическое агентство официально объявило о завершении миссии спутника.




Рис. 2.8. Фрагмент РЛИ, полученных с помощью сенсора AMI (режим SCAT).  
Атлантическое побережье северной Коста-Рики и южной Никарагуа [45].

На период с 2000 по 2010 годы Envisat являлся одним из самых крупных спутников ДЗЗ: суммарная масса аппарата составляла более 8000 кг, при этом он был оснащен девятью различными инструментами для мониторинга земной поверхности и атмосферы, включающими спектрометры MERIS, MIPAS и SCIAMACHY, сенсоры AATSR и GOMOS, радарный высотометр RA-2, радиометр MWR, система слежения DORIS и PCA-датчик ASAR [19] (рис. 2.9). Спектрометр MERIS (Medium Resolution Imaging Spectrometer) предназначался для выполнения съемки водной поверхности в видимом и ближнем инфракрасном диапазонах (длины волн от 390 до 1040 нм). Основная задача заключалась в мониторинге цвета воды океанов с целью последующего анализа ее химического состава. Сенсор AATSR (Advanced Along Track Scanning Radiometer) представлял собой улучшенную версию инструментов ATSR космических аппаратов миссии ERS и использовался для измерения температуры морской поверхности

с точностью до 0,3 К. Полученные данные в основном использовались в качестве опорных при прогнозировании климатических изменений, также среди вторичных задач сенсора следует отметить мониторинг состава и динамики растительности. Радар RA-2 (Radar Altimeter 2) осуществлял надирные наблюдения в Ku- и S-диапазонах и преимущественно применялся для изучения океанического рельефа, также осуществлял наблюдения за ледовым покрытием. Радиометр MWR (Microwave Radiometer) предназначался для измерения процентного содержания водяного пара в атмосфере. Микроволновая следящая система DORIS (Doppler Orbitography and Radiopositioning Integrated by Satellite) выполняла задачу по позиционированию спутника на орбите, при этом заявленная точность определения координат составляла 10 см. Сенсор GOMOS (Global Ozone Monitoring by Occultation of Stars) осуществлял наблюдения за изображениями звёзд через толщу высоких слоев атмосферы<sup>15</sup>. Сравнивая цвет полученных образов с эталонными изображениями можно было сделать выводы о процентном соотношении и пространственном распределении различных атмосферных компонент. Фурье-спектрометр среднего инфракрасного диапазона MIPAS (Michelson Interferometer for Passive Atmospheric Sounding) применялся для измерения давления и температуры различных соединений (диоксид азота  $\text{NO}_2$ , закись азота  $\text{N}_2\text{O}$ , метан  $\text{CH}_4$ , азотная кислота  $\text{HNO}_3$ , озон  $\text{O}_3$ ) в стратосфере. Спектрометр SCIAMACHY (SCanning Imaging Absorption spectroMeter for Atmospheric CHartography) применялся для построения карт распределения различных газов и аэрозолей в тропосфере и стратосфере. Наконец, ASAR (Advanced Synthetic Aperture Radar) представлял собой РСА-датчик С-диапазона (рабочая длина волны 5,6 см).




Рис. 2.9. Целевая аппаратура спутника Envisat [20]

<sup>15</sup> Обозначенный метод измерения основан на приеме покрытия — явления, во время которого, с точки зрения наблюдателя из определённой точки, одно небесное тело проходит перед другим небесным телом, заслоняя его полностью или частично [20].



Сенсор ASAR осуществлял съемку в пяти различных режимах: режим изображения (Image Mode), режим переменной поляризации (Alternating Polarisation), полосовой режим (Wide Swath), режим глобального мониторинга (Global Monitoring) и волновой режим (Wave Mode).

Режим изображения использовался для получения РЛИ высокого пространственного разрешения (до 30 м) и являлся наиболее часто используемым для спутника Envisat. Полосовой режим был сканирующим с возможностью получения изображения среднего пространственного разрешения с полосой обзора до 405 км. В режиме глобального мониторинга осуществлялось формирование изображений низкого разрешения (1 км), применяющихся для решения задач наблюдения ледовой и водной поверхностей, лесных вырубок, а также анализа влажности почв. Волновой режим представлял собой прожекторный режим съемки, формирование данных происходило с интервалом между кадрами 100 км, а пространственное разрешение составляло до 10 м. Режим переменной поляризации позволял получать изображения земной поверхности в двойной поляризации (HH + VV, HH + HV, VV + VH). Остальные четыре режима позволяли осуществлять съемку только в режиме одиночной поляризации (HH либо VV). Скорость передачи всех данных составляла 100 Мбит/с, радиометрическое разрешение 8 бит, периодичность съемки от 2,5 до 35 дней [21]. Технические параметры режимов работы сенсора приведены в табл. 2.5. На рис. 2.10 приведен фрагмент изображения, полученного с помощью датчика ASAR космического аппарата Envisat в режиме изображения.

Таблица 2.5  
Основные режимы работы сенсора ASAR спутника Envisat

| Режим                    | Пространственное разрешение, м | Полоса обзора, км | Угол визирования, ° |
|--------------------------|--------------------------------|-------------------|---------------------|
| Image Mode               | 30                             | 105               | 15–45               |
| Wave Mode                | 10                             | 10                | 15–45               |
| Global Monitoring        | 1000                           | 1000              | 17–42               |
| Wide Swath               | 150                            | 405               | 17–42               |
| Alternating Polarisation | 30                             | 105               | 15–45               |




Рис. 2.10. Фрагмент изображения, полученного с помощью сенсора ASAR спутника Envisat. Северный берег Аляски (нижний левый угол) и морской лед в море Бофорта [22]



## 2.5. RADARSAT

RADARSAT — канадская программа спутников ДЗЗ, разработанная для мониторинга земной поверхности в радиодиапазоне, а также решения задач наблюдения за климатом. Владелец аппаратов является Канадское космическое агентство. Первый из спутников программы, RADARSAT-1, был выведен на солнечно-синхронную орбиту (апоцентр 821 км, перигей 793 км, наклонение  $98,6^\circ$ ) в ноябре 1995 года [23]. В последствии было установлено, что данные космического аппарата могут быть применимы во многих научных и практических отраслях, таких как контроль качества агрономических культур, мониторинг гидрографической и ледовой обстановок, растительности, картография, океанология и геология. Основным инструментом RADARSAT-1 являлся PCA-сенсор С-диапазона (рабочая длина волны 5,6 см), обеспечивающий получение изображений с пространственным разрешением до 8 м. Следует отметить, что на момент запуска спутника обозначенный сенсор был первым, поддерживающим возможность изменения угла визирования за счет использования антенных фазированных решеток. RADARSAT-1 прекратил передачу данных в марте 2013 года, прослужив в общей сложности более 17 лет.

Следующим аппаратом миссии становится RADARSAT-2, выведенный на ту же орбиту в декабре 2007 года [23] и продолжающий сбор данных по настоящее время. Характеристики PCA-сенсора второго спутника миссии во многом превосходят параметры своего предшественника, в том числе обеспечивают более высокое пространственное разрешение (до 3 м) и возможность выбора типа поляризации импульса. Кроме того, на аппарате реализована возможность съемки областей как с левой, так и с правой стороны относительно траектории полета, что позволяет увеличить временное разрешение поставляемых данных. Применение его снимков включает картирование морских льдов и геологических пород, наблюдение за сельскохозяйственными культурами, контроль загрязнений окружающей среды и береговую охрану территории Канады.

Наконец, группировка RADARSAT Constellation Mission (RCM) представляет собой систему из трех идентичных спутников, продолжающих задачи аппаратов более ранних поколений, а также предлагающих широкий спектр всевозможных задач практического использования за счет уменьшения интервалов между съемками [24]. В перспективе планируется увеличить количество аппаратов до шести. Спутники выведены на общую солнечно синхронную орбиту в июне 2019 года, высота орбиты составила 600 км, наклонение  $97,74^\circ$ . Угловое расстояние между аппаратами одинаковое и составляет  $120^\circ$  (рис. 2.11). Благодаря такой конфигурации на орбите использование RCM позволяет просматривать до 90 % земной поверхности с периодичностью в один день, за счет чего заказчики могут получать необходимую информацию практически в реальном режиме времени. Дополнительно к PCA-датчику каждый из аппаратов оснащён автоматической системой идентификации судов (AIS), которая может использоваться параллельно с основным сенсором. Сравнительные характеристики аппаратов миссии RADARSAT приведены в табл. 2.6 [24].

Рассмотрим более подробно сенсоры спутников миссии RADARSAT. PCA-датчик космического аппарата RADARSAT-1 осуществлял съемку с использованием только одиночного типа поляризации (HH), при этом угол визирования изменялся в пределах от  $10^\circ$  до  $59^\circ$  с правой стороны относительно траектории движения спутника. Принято различать пять основных режимов работы сенсора: маршрутный (Fine),

маршрутный с накоплением (Standart), маршрутный широкозахватный (Wide), маршрутный с увеличенным углом визирования (Extended) и сканирующий (ScanSAR) [25]. Режим работы Fine представлял собой режим по умолчанию и обеспечивал формирование РЛИ с пространственным разрешением до 8 м.

Таблица 2.6

Сравнительные характеристики аппаратов миссии RADARSAT

| Параметр                  | RADARSAT-1                  | RADARSAT-2                       | RCM                              |
|---------------------------|-----------------------------|----------------------------------|----------------------------------|
| Дата запуска              | 4.11.1995                   | 14.12.2007                       | 12.06.2019                       |
| Полное покрытие           | 2–3 дня                     | 2–3 дня                          | ежедневное                       |
| Масса, кг                 | 2750                        | 2200                             | 1400 (каждый аппарат)            |
| Размеры антенны, м        | 15×1,5                      | 15×1,5                           | 6,75×1,38                        |
| Размеры солнечных панелей | 2,21×1,32 м<br>(две панели) | 3,73×1,8 м<br>(две панели)       | 2,21,7 м<br>(одна панель)        |
| Направление обзора        | Правый                      | Правый и левый                   | Правый                           |
| Поляризация               | Одиночная (HH)              | Одиночная, двойная, полный базис | Одиночная, двойная, полный базис |
| Средняя высота, км        | 800                         | 800                              | 600                              |




Рис. 2.11. Орбитальная конфигурация аппаратов группировки RCM

Маршрутный режим с накоплением отличался от режима Fine тем, что в нем применялось накопление сигнала, что позволяло уменьшить спекл-шум на итоговом изображении. Широкозахватный маршрутный режим подразделялся на два подрежима: Wide 1 и Wide 2, которые отличались углами визирования и, как следствие, шириной полосы обзора. Маршрутный режим с увеличенным углом визирования также подразделялся на два подрежима – Extended High и Extended Low, позволяющими осуществлять наблюдения на экстремально больших (High) и экстремально малых (Low) углах визирования. В сканирующем режиме также принято различать два подрежима – сканирующий широкий (Wide) и сканирующий узкий (Narrow) режимы съемки. Отличие между ними заключалось в различной ширине полосы обзора приблизительно в два раза (3:5), и, соответственно, в различном пространственном разрешении (1:2). Основные технические характеристики режимов съемки приведены в табл. 2.7.

Таблица 2.7

Основные режимы съемки PCA-сенсора спутника RADARSAT-1

| Режим          | Пространственное разрешение, м | Полоса обзора, км | Угол визирования, ° |
|----------------|--------------------------------|-------------------|---------------------|
| Fine           | 8                              | 45                | 37–48               |
| Standard       | 25                             | 100               | 20–49               |
| Extended High  | 25                             | 75                | 50–60               |
| Extended Low   | 25                             | 170               | 10–23               |
| Wide 1         | 30                             | 165               | 20–31               |
| Wide 2         | 30                             | 150               | 31–39               |
| ScanSAR Narrow | 50                             | 305               | 20–40               |
| ScanSAR Wide   | 100                            | 510               | 20–49               |

Данные космического аппарата RADARSAT-1 нашли широкое применение в самых разных отраслях науки и техники, в том числе использовались в проекте АММ [23], результатом работы которого стало создание изображения высокого разрешения (25 м) территории Антарктиды (рис. 2.12). Полученный продукт содержит детальную информацию о морфологии ледяного покрова, выхода пород, информацию о береговой линии и прочие характеристики, которые до сих пор используются в качестве опорных для оценки изменений полярного ледяного покрова.

Как отмечалось выше, сенсор спутника RADARSAT-2 отличается большей гибкостью в управлении углом визирования (и, соответственно, большей полосой обзора) и возможностью выбора режима поляризации [26]. Помимо режимов съемки, имеющихся у аппарата RADARSAT-1 (табл. 2.7), RADARSAT-2 обеспечивает съемку в двенадцати принципиально новых режимах, а именно, сверхвысокого разрешения (SpotLight A), детальный маршрутный (Ultra Fine), широкозахватный детальный маршрутный (Wide Ultra Fine), маршрутный с накоплением (Multi-look Fine), широкозахватный маршрутный с накоплением (Wide Multi-look Fine), улучшенный маршрутный (Extra Fine), широкозахватный маршрутный (Wide Fine), широкозахватный маршрутный с полным поляризационным базисом (Wide Fine Quad), стандартный маршрутный с полным поляризационным базисом (Standard Quad), широкозахватный стандартный маршрутный с полным поляризационным базисом (Wide Standard

Quad), режим наблюдения за океаном (Ocean Surveillance), режим обнаружения кораблей (Ship Detection) [27]. Режим сверхвысокого разрешения представляет собой проекторный режим съемки, обеспечивающий формирование РЛИ с пространственным разрешением до 1,5 м. В этом режиме доступна только одиночная поляризация (HH, VV, HV либо VH). Фрагмент изображения земной поверхности, полученного в этом режиме, приведен на рис. 2.13.




Рис. 2.12. Изображение территории Антарктики, составленного по более чем 8000 космоснимков аппарата RADARSAT-1 (маршрутные режимы съемки) [23]

Еще девять новых режимов представляют собой различные модификации маршрутного режима. С использованием стандартного маршрутного режима съемки (Standart) можно получить космоснимки с пространственным разрешением до 15 м, тогда как маршрутный режим (Fine) позволяет сформировать изображения с пространственным разрешением до 6,5 м, но с меньшей полосой обзора (100 км против 50 км). В детальном маршрутном режиме возможно получение изображений с пространственным разрешением до 3 м, широкозахватный детальный маршрутный режим обеспечивает формирование РЛИ с такими же параметрами, но в увеличенной (до 50 км) полосе обзора. Для обоих режимов доступна только одиночная поляризация (HH, VV, HV либо VH). Фрагмент изображения, полученный в детальном маршрутном режиме, показан на рис. 2.14. Маршрутный режим съемки с накоплением позволяет достичь снижения шума на изображении без потери в пространственном разрешении, составляющем 5 м.



Соответственно, широкозахватный маршрутный режим съемки с накоплением позволяет получить РЛИ того же качества, но с увеличенной (до 90 км) полосой обзора. Съемка в обоих режимах осуществляется только в режиме одиночной поляризации (HH, VV, HV либо VH). Улучшенный маршрутный режим позволяет получать изображения с полосой охвата, как и в широкозахватном маршрутном режиме (до 160 км), но с более высоким пространственным разрешением (до 5 м), тогда как в широкозахватном маршрутном режиме формируются изображения с пространственным разрешением 8 м как при одиночной (HH, VV, HV либо VH), так и в двойной (HH + HV либо VV + VH) поляризациях. Использование двойной поляризации возможно при съемке в маршрутном, маршрутном с накоплением, широкозахватном и широкозахватном маршрутном режимах. Маршрутные режимы с отметкой Quad (широкозахватный маршрутный, маршрутный с накоплением и расширенный маршрутный с накоплением) позволяют получать РЛИ в полном поляризационном базисе (HH + VV + HV + VH).




Рис. 2.13. Фрагмент изображения, полученного с помощью PCA-датчика RADARSAT-2 (прожекторный режим съемки) [23]

Режимы наблюдения за океаном и обнаружения кораблей относятся к сканирующему типу съемки и предназначены для фиксации образов кораблей на обширных водных поверхностях. Из-за специфики процедуры обнаружения морских судов для обоих режимов применяется усиленное сжатие по азимуту в ближних каналах дальности и подавление шумов на больших наклонных дальностях.





Рис. 2.14. Фрагмент изображения, полученного с помощью PCA-датчика RADARSAT-2 (детальный маршрутный режим) [23]

При съемке в режиме обнаружения кораблей осуществляется самая высокая степень сжатия данных из возможных, поэтому для формируемых РЛИ характерен высокий уровень шума, благодаря анализу которого становится возможным определить небольшие суда в рамках существенной площади кадра (рис. 2.15). В этом режиме возможно осуществлять съемку во всех режимах одиночной поляризации (HH, VV, HV либо VH), однако в виду преимущественно горизонтальной ориентации судов в пространстве предпочтительным является тип поляризации HH (см. часть 2, раздел VI). Пространственное разрешение формируемых изображений составляет 30 м. Режим наблюдения за океаном подобен режиму обнаружения кораблей, однако в этом случае соблюдается баланс между эффективностью поиска целей и шумовыми компонентами для возможности применения получаемых данных в иных практических приложениях. В этом режиме возможно применение как одиночной (HH, VV, HV либо VH), так и двойной (HH + HV либо VV + VH) поляризации. При решении задач обнаружения морских судов на водной поверхности предпочтительнее использовать двойную поляризацию типа (HH + HV), тогда как для таких задач, как определение параметров приповерхностных ветров и обнаружение нефти на поверхности воды более полезной оказывается поляризация типа (VV + VH). Как для режима обнаружения кораблей, так и для режима наблюдения за океаном характерна максимально широкая полоса охвата (до 510 км). Следует отметить, что PCA-датчик спутника RADARSAT-2 обеспечивает съемку в сканирующем широком и сканирующем узком режимах работы как при одиночной (HH, VV, HV либо VH), так и при двойной (HH + HV либо VV + VH) поляризациях.

Наконец, спутники группировки RCM являются продолжением миссии RADARSAT, дополняя и расширяя возможности своих предшественников за счет сокращения времени между съемками одной и той же местности. Полезная нагрузка каждого из аппаратов состоит из идентичных РСА-датчиков, интегрированных автоматизированной системой идентификации судов (AIS) [28]. Каждый из сенсоров осуществляет съемку в восьми режимах работы: сверхвысокого разрешения (Spotlight), высокого разрешения (High Resolution), очень высокого разрешения (Very High Resolution), полного поляризационного базиса (Quad-Polarization), среднего разрешения (Medium Resolution), низкого разрешения (Low Resolution), низкошумного (Low Noise), обнаружения кораблей (Ship Detection).




Рис. 2.15. Фрагмент изображения, полученного с помощью РСА-датчика RADARSAT-2 (режим обнаружения кораблей) [23]

В табл. 2.8 приведены основные параметры режимов съемки аппарата RADARSAT-2. Режим сверхвысокого разрешения является прожекторным и обеспечивает фиксацию земной поверхности с детализацией до 1 м. Режимы высокого разрешения, очень высокого разрешения и полного поляризационного базиса представляют собой вариации маршрутного режима, обеспечивающих формирование РЛИ с пространственным разрешением от 3 до 9 м, причем режим Quad-Polarization осуществляет съемку в полном поляризационном базисе. Режим среднего разрешения подразделяется на три подрежима, обеспечивающих пространственное разрешение изображений, равное 16, 30 и 50 м. Первые два подрежима по технической реализации относятся к маршрутному режиму съемки, тогда как последний — к сканирующему.

Таблица 2.8

Режимы съемки PCA-сенсора спутника RADARSAT-2

| Режим                | Пространственное разрешение, м | Полоса обзора, км | Угол визирования, ° |
|----------------------|--------------------------------|-------------------|---------------------|
| SpotLight A          | 1,5                            | 18                | 20–50               |
| Ultra Fine           | 3                              | 20                | 30–50               |
| Wide Ultra Fine      | 3                              | 50                | 30–50               |
| Multi-look Fine      | 5                              | 50                | 29–50               |
| Wide Multi-look Fine | 5                              | 90                | 29–50               |
| Extra Fine           | 5                              | 160               | 22–49               |
| Fine                 | 6,5                            | 50                | 30–50               |
| Fine Quad            | 8                              | 25                | 18–49               |
| Wide Fine            | 8                              | 160               | 20–45               |
| Wide Fine Quad       | 9                              | 50                | 18–42               |
| Wide                 | 10                             | 170               | 18–45               |
| Extended High        | 10                             | 80                | 49–60               |
| Standard Quad        | 12                             | 25                | 18–49               |
| Wide Standard Quad   | 12                             | 50                | 18–42               |
| Standart             | 15                             | 100               | 20–52               |
| Extended Low         | 15                             | 170               | 10–23               |
| Ship Detection       | 35                             | 510               | 35–56               |
| ScanSAR Narrow       | 50                             | 305               | 20–47               |
| Ocean Surveillance   | 50                             | 510               | 20–50               |
| ScanSAR Wide         | 100                            | 510               | 20–49               |

Также к сканирующему режиму съемки относятся режимы низкого разрешения, обнаружения кораблей и низкошумный режим. Как и для PCA-датчика аппарата RADARSAT-2, для режима обнаружения кораблей характерно максимальное увеличение амплитуды отклика от цели по отношению к фоновому шуму, включающему две разные составляющие: тепловой шум и помехи, вызванные возмущением водной поверхности. При съемке местности в низкошумном режиме используется несколько более широкая диаграмма направленности по сравнению с прочими сканирующими режимами, что позволяет осуществить накопление сигнала при сохранении величины пространственного разрешения. Данные, полученные в этом режиме, находят широкое применение при решении задач мониторинга нефти и льда на водной поверхности [29]. Фрагмент изображения, полученного в низкошумном режиме, приведен на рис. 2.16. Для всех указанных режимов, за исключением сверхвысокого разрешения, низкошумного и обнаружения кораблей, возможна съемка как при одиночной (HH, VV, HV либо VH), так и при двойной (HH + HV, VV + VH либо HH + VV) поляризациях,



тогда как для отмеченных режимов в случае применения двойной поляризации возможно только использование комбинаций поляризации волны HH + HV либо VV + VH. Основные параметры режимов съемки аппаратов RCM представлены в табл. 2.9.



Рис. 2.16. Фрагмент изображения, полученного с помощью группировки спутников RCM (низкошумный режим). Изображение морского льда в проливе Дэвиса и побережье острова Баффин, Нунавут, июнь 2019 года [24]

Таблица 2.9  
Режимы съемки РСА-сенсоров спутников группировки RCM

| Режим                | Пространственное разрешение, м | Полоса обзора, км | Угол визирования, ° |
|----------------------|--------------------------------|-------------------|---------------------|
| Spotlight            | 1                              | 20                | 19–54               |
| Very High Resolution | 3                              | 20                | 18–54               |
| High Resolution      | 5                              | 30                | 19–54               |
| Quad-Polarization    | 9                              | 20                | 19–54               |
| Medium Resolution 1  | 16                             | 30                | 20–47               |
| Medium Resolution 2  | 30                             | 125               | 21–47               |
| Medium Resolution 3  | 50                             | 350               | 19–58               |
| Low Resolution       | 100                            | 500               | 19–54               |
| Low Noise            | 100                            | 350               | 19–58               |
| Ship Detection       | 25                             | 600               | 35–56               |

## 2.6. Sentinel

Sentinel – семейство спутников дистанционного зондирования Земли Европейского космического агентства, предназначенных для контроля землепользования, мониторинга растительности и водных ресурсов, для операций по ликвидации последствий стихийных бедствий. Первая миссия, Sentinel-1, состоит из двух аппаратов,

обозначаемых как –1А и –1В, расположенных на общей солнечно-синхронной орбите высотой 693 км и наклоном 98,2° в противоположных орбитальных точках [30]. Спутник Sentinel-1А запущен в апреле 2014, Sentinel-1В – в апреле 2016 года. Данные миссии Sentinel-1 находят широкое применение в решении самых разных задач, в частности, регулярные наблюдения моря и суши, мониторинг последствий природных бедствий, оценка влажности почвы, а также имеют различные экономические приложения. Оба аппарата оснащены РСА-датчиком С-диапазона (рабочая длина волны 5,6 см) правого бокового обзора, представляющего собой фазированную антенную решетку. В настоящее время ведутся работы над продолжением миссии в виде аппаратов Sentinel-1С и -1D, даты запуска которых пока не определены.

Каждый из сенсоров Sentinel-1 поддерживает четыре режима работы: маршрутный (Stripmap), интерферометрический (Interferometric Wide Swath), сверхширокий (Extra-Wide Swath) и волновой (Wave Mode) (табл. 2.10). Данные, полученные в маршрутном режиме, представляют собой типичные РЛИ с пространственным разрешением до 5 м. Интерферометрический режим обеспечивает получение данных высокого разрешения, наиболее частое применение которых заключается в формировании трехмерных цифровых моделей рельефа и обнаружения его изменений. Этот же режим съемки используется по умолчанию при мониторинге поверхности суши. Режим сверхширокого обзора (сканирующий режим) предназначен для оперативных наблюдений морских приполярных территорий, в этом случае формируются РЛИ среднего пространственного разрешения, которые также могут быть использованы в задачах интерферометрии. Волновой режим применяется для определения направления, высоты и длины волны в открытом океане. При использовании маршрутного, интерферометрического и сверхширокого режимов возможны наблюдения как в одиночной (НН либо VV), так и в двойной поляризации (НН + НV, VV + VН), данные которой оказались особенно полезны в решении задач по классификации типов морского льда. В волновом режиме доступна съемка только с применением одиночной поляризации (НН либо VV).

Таблица 2.10  
Основные режимы работы РСА-сенсоров спутников Sentinel-1

| Режим                      | Пространственное разрешение, м | Полоса обзора, км | Угол визирования, ° |
|----------------------------|--------------------------------|-------------------|---------------------|
| Stripmap                   | 5                              | 80                | 18–47               |
| Interferometric Wide Swath | 20                             | 250               | 29–46               |
| Extra-Wide Swath           | 100                            | 400               | 19–47               |
| Wave Mode                  | 20                             | 20                | 22–38               |

Следующим поколением спутников миссии Sentinel становятся аппараты –2А (запуск июнь 2015 года) и –2В (запуск март 2017 года), предназначенные для контроля использования земных угодий, растительности, сельскохозяйственных и водных ресурсов в рамках программы Коперник (Copernicus) [32, 33]. Как и в случае спутников Sentinel-1, космические аппараты располагаются на одной солнечно-синхронной орбите (высота 786 км, наклонение 98,6°) на расстоянии 180° друг от друга. В отличие от своих предшественников, аппараты Sentinel-2 осуществляют съемку в оптической



и инфракрасной зонах спектра с пространственным разрешением от 10 до 60 м и шириной обзора 290 км. В настоящий момент ведутся работы по созданию спутников Sentinel-2C и Sentinel-2D, которые будут выведены на орбиту после 2021 года в целях поддержания действующей программы.

На рис. 2.17 представлен фрагмент изображения, полученного с применением РСА-датчика одного из аппаратов миссии Sentinel-1.




Рис. 2.17. Фрагмент изображения, полученного с помощью группировки спутников Sentinel-1 (режим Interferometric Wide Swath). Юго-запад Стамбула, Турция, 2018 год [31]

Наконец, третьим этапом космической миссии Sentinel становятся спутники –3А и –3В. Названные аппараты являются улучшенными версиями спутников Envisat и ERS-2. Как и их предшественники, Sentinel-3А и -3В располагаются на общей солнечно-синхронной орбите высотой 815 км и наклоном  $98,7^\circ$  [34]. Вывод на орбиту аппарата Sentinel-3А произошел в феврале 2016 года, Sentinel-3В — в апреле 2018 года. Среди важнейших задач миссии Sentinel-3 стоит отметить следующие: топография водной поверхности, измерение температуры воды и суши, а также мониторинг окружающей среды и климатический контроль. Из полезной нагрузки на борту каждого из спутников установлено четыре различных датчика (рис. 2.18): температурный радиометр SLSTR (Sea and Land Surface Temperature Radiometer), измеряющий температуру поверхности воды с точностью до 0,3 К; спектрометр OLCI (Ocean and Land Colour Instrument), представляющий собой усовершенствованную версию сенсора MERIS аппарата Envisat и формирующий изображения земной поверхности в среднем пространственном разрешении в 21 спектральном канале; двух-частотный радиолокационный высотометр SRAL (Synthetic Aperture Radar Altimeter), работающий в Ku- и С-диапазонах и предназначенный для создания топографических карт поверхности океанов и морей, а также ледовых поверхностей. Сенсор предназначен для работы в двух режимах: высокого (SAR) и низкого (LRM) пространственных разрешений.

В октябре 2017 года на орбиту выведен аппарат Sentinel-5 Precursor (Sentinel-5P), предназначенный для мониторинга атмосферных загрязнений [35]. Основным инструментом спутника является спектрометр TROPOMI (TROPOspheric Monitoring Instrument), представляющий собой совместную разработку Европейского космического агентства и правительства Нидерландов. Основная задача спутника заключается в осуществлении измерений химических компонент воздуха с высоким пространственно-временным разрешением. Полученные данные используются для определения качества воздуха, мониторинга озонового слоя, а также служат модельной основой при прогнозировании климатических изменений.




Рис. 2.18. Целевая аппаратура спутников Sentinel-3 [34]

В настоящее время также ведутся работы по реализации миссий Sentinel-4, Sentinel-5 и Sentinel-6. Основной задачей спутников Sentinel-4 будет мониторинг химического состава атмосферы, а именно измерение процентного содержания таких соединений, как озон ( $O_3$ ), диоксид азота ( $NO_2$ ), диоксид серы ( $SO_2$ ), формальдегид ( $HCHO$ ), а также оценка оптической толщины аэрозолей [36]. Из полезной нагрузки на аппарате будут установлены спектрометры UVN (Ultraviolet Visible Near-infrared), охватывающие диапазоны от ультрафиолетового до ближнего инфракрасного, и тепловизоры IRS (Infrared Sounder), позволяющие получить трехмерное распределение температуры атмосферы и водяного пара. В настоящее время вывод на орбиту аппаратов Sentinel-4 запланирован на 2023 год. Аппаратура спутника Sentinel-5 (запуск в 2021 году) в целом будет аналогична Sentinel-4 за тем исключением, что он позволит оценивать количественное содержание соединений  $CO$ ,  $CH_4$  и  $O_3$  с ежедневным глобальным покрытием [37]. Основная задача спутников миссии Sentinel-6 будет заключаться в высотометрии уровня мирового океана, запуск аппаратов запланирован на конец 2020 (–6A) и начало 2026 (–6B) гг.

Следует отметить, что некоторые из космических снимков и производных данных, полученные с аппаратов миссий Sentinel, находятся в свободном доступе на официальном сайте проекта Коперник [38].

## 2.7. TerraSAR-X

TerraSAR-X (иногда обозначается как TSX) — спутник Немецкого аэрокосмического центра (DLR), запущенный в июне 2007 года [39]. Орбита аппарата солнечно-синхронная, высота в апогее составляет 516 км, высота в перигее — 514 км, наклонение —  $97,4^\circ$ . Движение спутника по орбите осуществляется вдоль линии терминатора таким образом, что аппарат всегда обращен в сторону Солнца, что обеспечивает оптимальное накопление энергии через солнечные батареи. Основным инструментом TerraSAR-X является радиолокатор с синтезированной апертурой Хдиапазона (рабочая длина волны 3,1 см) размером  $5 \times 0,8$  м, позволяющий осуществлять съемку земной поверхности с пространственным разрешением до 1 м, являясь по сути третьим аппаратом (после COSMO-SkyMed и RADARSAT-2), обеспечивающим формирование радиолокационных изображений со сверхвысоким разрешением. Среди основных задач спутника следует отметить составление и обновление топографических карт масштаба до 1:25000, мониторинг окружающей среды и экологической обстановки, а также обнаружение подвижек рельефа. Для спутника доступна возможность левой и правой боковой съемки, а также съемка в нескольких типах поляризации. Отличительной особенностью аппарата TerraSAR-X является короткое время реагирования, позволяющее осуществить выбор режима съемки и тип поляризации в течение трех секунд.

Рассмотрим подробнее PCA-сенсор спутника TerraSAR-X. Датчик поддерживает три основных режима работы: SpotLight, StripMap и ScanSAR (табл. 2.11). Режим SpotLight (прожекторный режим) предназначен для получения высоко детальных изображений с пространственным разрешением до 0,24 м. В нем принято различать три подрежима: собственно, SpotLight, High Resolution SpotLight, для которого также возможны реализации в одиночной (VV либо HH), либо двойной (HH + VV) поляризации, и Staring SpotLight, в котором антенна фиксируется на одной сцене на протяжении длительного времени синтеза, благодаря чему и формируется РЛИ сверхвысокого пространственного разрешения. Режим StripMap (маршрутный режим) аналогичен режиму датчика аппарата ERS-1 и является основным рабочим режимом для TerraSAR-X. В нем возможна реализация как одиночной поляризации (VV либо HH), так и двойной (HH + VV, HH + HV, либо VV + VH). Режим ScanSAR (сканирующий режим) также подразделяется на два подрежима: собственно ScanSAR и Wide ScanSAR. Оба они предназначены для глобального мониторинга земной поверхности в низком пространственном разрешении и с широкой полосой захвата. Оба подрежима поддерживают только одиночную поляризацию, причем для ScanSAR возможна реализация VV либо HH, для Wide ScanSAR — VV, HH, HV либо VH [40]. На рис. 2.19 приведен фрагмент изображения, полученного со спутника TerraSAR-X.

## 2.8. TanDEM-X

TanDEM-X — спутник-компаньон космического аппарата TerraSAR-X, являющийся его практически полной идентичной копией. Выведен на солнечно-синхронную орбиту в июне 2010 года. Средняя высота орбиты составляет 515 км, наклонение  $97,4^\circ$ , причем восходящий узел орбиты подобран таким образом, чтобы в каждый момент времени аппараты TerraSAR-X и TanDEM-X находились на расстоянии от 200 м до 3 км (в среднем 250–500 м), образуя оптимальный интерферометрический базис [42]. На рис. 2.20 представлен снимок с Земли обоих спутников, расстояние между которыми в момент съемки составило 70 угловых секунд.



Таблица 2.11  
Основные режимы работы РСА-датчика спутника TerraSAR-X

| Режим             | Пространственное разрешение, м       | Полоса обзора, км | Угол визирования, ° |
|-------------------|--------------------------------------|-------------------|---------------------|
| Staring SpotLight | 0,24 <sup>16</sup>                   | 4                 | 20–45               |
| HighRes SpotLight | 1,1                                  | 10                | 20–55               |
| SpotLight         | 1,7                                  | 10                | 20–55               |
| StripMap          | 3,3 <sup>17</sup> /6,6 <sup>18</sup> | 30/15             | 20–45               |
| ScanSAR           | 18,5                                 | 100               | 20–45               |
| Wide ScanSAR      | 40                                   | 270               | 16–49               |




Рис. 2.19. Фрагмент изображения, полученного с помощью спутника TerraSAR-X (режим StripMap). Порт города Керчь, Россия [41]



Рис. 2.20. Космические аппараты TerraSAR-X и TanDEM-X (фото Марко Лангбрука, Лейден, Нидерланды, экспозиция кадра 10 с)

<sup>16</sup> Только для военных миссий.

<sup>17</sup> В режиме одиночной поляризации.

<sup>18</sup> В режиме одиночной поляризации.



Задачи аппарата TanDEM-X схожи с задачами его предшественника. Среди основных из них следует отметить наблюдение и оценку динамики таяния ледников, мониторинг зон вечной мерзлоты и растительности [43]. Кроме того, совместное использование данных с TerraSAR-X и TanDEM-X в конфигурации, показанной на рис. 2.18, позволяет осуществлять высокоточную интерферометрическую обработку (заявленная точность порядка см), а также применяется в создании глобальной цифровой модели рельефа с точностью по относительной высоте до 2 м, материалы которой легли в основу проекта WorldDEM [44]. Глобальная цифровая модель рельефа WorldDEM является высокодетальным продуктом с полным охватом земной поверхности, пришедшая на смену продукту SRTM [45] в 2014 году. На рис. 2.21 приведены фрагменты цифровой модели рельефа SRTM и WorldDEM.




Рис. 2.21. Фрагменты цифровых моделей рельефа:  
а – SRTM (пространственное разрешение 90 м);  
б – WorldDEM (пространственное разрешение 12 м) [46]

Коммерческий успех аппаратов TerraSAR-X и TanDEM-X положил начало разработке миссии следующего поколения – TanDEM-L, состоящего из двух идентичных аппаратов, оснащенных РСА-датчиком L-диапазона (рабочая длина волны 23,6 см). Помимо дополнения данных своих предшественников, в задачи миссии TanDEM-L будет входить предсказание землетрясений за счет наблюдений подвижек рельефа с точностью порядка мм, мониторинг движения ледников и другие задачи, связанные с динамикой земного покрова. Запуск аппаратов предварительно запланирован на 2022 год.

## 2.9. PAZ

PAZ – испанский спутник дистанционного зондирования Земли, оборудованный РСА-датчиком X-диапазона (рабочая длина волны 3,1 см). Запуск состоялся в феврале 2018 года, высота солнечно-синхронной орбиты 508 км, наклонение 97,4° [47]. Спутник PAZ является дополнением миссии космических аппаратов TerraSAR-X и TanDEM-X, позволяющим улучшить временное разрешение для задач мониторинга окружающей среды и предотвращения чрезвычайных ситуаций. Также космоснимки

PAZ применяются для пограничного контроля и разведки, планирования развития инфраструктуры и мониторинга стихийных бедствий.

Размер антенны PCA-датчика составляет 4,8×0,7 м. Поддерживается три основных режима работы: прожекторный SpotLight, маршрутный StripMap и сканирующий ScanSAR [48] (табл. 2.12). Прожекторный режим съемки подразделяется на два подрежима: собственно, SpotLight, позволяющий формировать РЛИ с пространственным разрешением до 1 м, и Staring SpotLight, обеспечивающий детальность изображений до 0,25 м. Маршрутный режим является режимом работы сенсора по умолчанию. Маршрутный и прожекторный режимы работы поддерживают как одиночный (HH, VV, HV либо VH), так и двойной (HH + HV, VV + VH либо HH + VV) тип поляризации. В сканирующем режиме работы также выделяют два подрежима: ScanSAR, обеспечивающий охват территории до 150 км в среднем пространственном разрешении, и режим сверхширокого обзора Wide Swathe ScanRadar с охватом местности до 270 км. В сканирующем режиме съемки поддерживается только одиночный тип поляризации (HH, VV, HV либо VH). Спутник обеспечивает формирование более чем 200 радиолокационных космоснимков за один день. На рис. 2.22 приведен фрагмент РЛИ, полученного с использованием аппаратуры спутника PAZ.

Таблица 2.12

Основные режимы работы PCA-датчика аппарата PAZ

| Режим             | Пространственное разрешение, м   | Полоса обзора, км | Угол визирования, ° |
|-------------------|----------------------------------|-------------------|---------------------|
| Staring SpotLight | 0,25 <sup>19</sup>               | 4                 | 20–55               |
| SpotLight         | 1                                | 5                 | 20–55               |
| StripMap          | 3 <sup>20</sup> /6 <sup>21</sup> | 30/15             | 20–45               |
| ScanSAR           | 18,5                             | 150               | 20–45               |
| Wide Swathe       | 40                               | 270               | 16–49               |




Рис. 2.22. Фрагмент космоснимка, полученного с космического аппарата PAZ (режим SpotLight, поляризация VV + HR), Сиэтл, штат Вашингтон, США, апрель 2018 год [47]

<sup>19</sup> Только для военных миссий.

<sup>20</sup> В режиме одиночной поляризации.

<sup>21</sup> В режиме двойной поляризации.

Логическим дополнением миссии аппарата PAZ становится спутник Ingenio (SEOSAT-Ingenio), выведенный на орбиту в сентябре 2020 года (высота орбиты 670 км, наклонение  $98,0^\circ$ ) [49]. Полезная нагрузка спутника включает три инструмента: мультиспектральную камеру, обеспечивающую оптическую съемку земной поверхности в многозональном режиме (пространственное разрешение 10 м), панхроматическую камеру (пространственное разрешение 2,5 м) и датчик наблюдения за атмосферой в видимом и ультрафиолетовом диапазонах.

## 2.10. Малые космические аппараты

С развитием космических технологий и расширением номенклатуры решаемых задач размеры современных космических аппаратов становятся всё меньше, как и потребляемая ими энергия. Современные космические аппараты делятся на большие (масса более 1000 кг), средние (500–1000 кг), малые (МКА) (масса меньше 500 кг), мини (100–500 кг), микро (10–100 кг).

Преимущества МКА заключаются в том, что они относительно недороги, легко модифицируются для решения определенных задач, создают меньше радиопомех. Применение МКА снижает финансовые потери в случае отказа или утраты такого спутника.

МКА увеличивают оперативность получения данных наблюдения за счёт увеличения численности группировки при тех же или меньших затратах, чем для запуска и эксплуатации одного «большого» спутника. Большие одиночные спутники имеют слишком большой период повторения съемки (американский Landsat-7 имеет периодичность 16 суток, французский Spot-5 – 3 суток).

Далее рассмотрим наиболее известные и широко распространённые группировки малых космических аппаратов [50–55, 85, 86].

1. Быстро развёртываемая американская группировка МКА TacSat (Tactical Satellite) (рис. 2.23).




Рис. 2.23. МКА TopSat

2. Спутник TacSat-2 (рис. 2.24). имеет массу 415 кг выводится на высоту 350 км. На спутнике расположен оптический телескоп, получающий изображение с разрешением 1 м. Спутник производит видовую и радиотехническую разведку, следит за перемещением судов.

Спутник связи TacSat-4 (микроспутник массой 0,4 кг) даёт возможность связи с мобильными группами передового развертывания вплоть до компактной радиостанции



военнослужащего или переносной радиостанции подразделения. Он обеспечивает три двухчасовые сеансы связи в сутки в любом районе Земного шара. Концепция создания и применения тактических спутников предусматривает их непосредственное использование командованием на театре военных действий.



Рис. 2.24. МКА TacSat-2 на заводе

1. В Великобритании реализуется программа TopSat (Tactical Optical Satellite – тактический оптический спутник), имеющий разрешение 2,5 м и массу 112 кг (рис. 2.25).



Рис. 2.25. МКА TacSat-3





Рис. 2.26. ТНС-1

1. Многоспутниковые группировки относительно недороги, легко изменяют свой функционал для решения новых задач, создают меньше радиопомех, существенно увеличивают оперативность получения и обработки полезной информации.

2. Малые КА позволяют отрабатывать новые технологии и эффективно решать отдельные конкретные задачи космических исследований в различных областях науки (астрономия, астрофизика, космическая физика, физика Солнца, космическая биология).

3. Малые аппараты меньшей массы (нано- и пр.) могут разрабатываться и использоваться высшими учебными заведениями (МГТУ им. Н.Э. Баумана, МАИ, Самарский национальный исследовательский университет им. академика С.П. Королева, Национальный исследовательский Томский политехнический университет, Сибирский государственный аэрокосмический университет им. академика М.Ф. Решетнёва и ряд других).

Несмотря на достаточно широкий размерный и функциональный диапазон, в целом современные МКА можно отнести к одной из трех групп.

Технологические МКА используются для разработки и исследования новых инновационных технологий.

Научные МКА дают возможность получения новых результатов в области солнечной и космической физики, планетологии, астрономии и астрофизики, науки о Земле, космической биологии и т. д.

2. Израильский МКА Egos-B имеет разрешение 0,7 м при массе 300 кг.

3. Российский космонавт Салижан Шарипов в 2005 году с борта МКС бросил рукой в космос первый российский наноспутник ТНС-1 массой 4,5 кг (рис. 2.26). Полоса обзора 250–300 км, разрешение — 50–100 м. Спутник имеет очень широкое применение, управляется простым ноутбуком из любого места.

Отечественный МКА дистанционного зондирования «Канопус-В» (масса менее 500 кг, разрешение — 2,1 м) применяется для картографирования, мониторинга чрезвычайных ситуаций, в том числе пожаров, оперативного наблюдения заданных районов и передает изображения на наземные пункты.

8 июля 2014 г. состоялся запуск российского спутника DX-1 (22 кг), обеспечивающий автоматическое слежение за морскими судами.

По прогнозу SpaceWorks [55] к 2022 г. будет использоваться более трех тысяч МКА.

Причины роста числа и популярности МКА заключаются в следующем [56–61].

В образовательном процессе малые спутники позволяют студентам получить знания о реальном процессе создания и внедрения космической техники, проверить теоретические выкладки и освоить на практике процесс их внедрения.

Кроме того, образовательные проекты по МКА представляют собой удобную платформу для реализации международного сотрудничества. Удачным примером является программа QB50, европейская инициатива по исследованию атмосферы, включающая запуск 50 спутников стандарта CubeSat. В проекте участвуют команды, представляющие образовательные учреждения (возможно, в сотрудничестве с коммерческими фирмами) из более чем 20 стран (Австрия, Австралия, Канада, Бразилия, Китай, ЮАР, Чехия, Германия, Испания, Финляндия, Франция, Великобритания, Греция, Израиль, Индия, Корея, Литва, Нидерланды, Турция, Тайвань, Украина, США, Румыния, Португалия и Россия). Программа QB50 со своей стороны финансирует 75 % затрат, университеты, помимо собственно участия в разработке спутника, софинансируют проект.

Известны и интересны планы взаимодействия российского и китайского космического сообщества по тематике МКА. Соответствующая программа реализуется, в частности, в рамках Ассоциации технических университетов России и Китая (АТУРК). В Программе запуска малых спутников АТУРК принимают участие 10 университетов: МГТУ им. Н.Э. Баумана, МАИ, Самарский аэрокосмический университет, Амурский государственный университет, Уральский федеральный университет, Harbin Institute of Technology, Northwestern Polytechnical University, Beihang University, Nanjing University of Aeronautics and Astronautics и Xi'an Jiaotong University. Предполагается, что первый российско-китайский студенческий спутник Partner будет запущен в 2020 г.

В 2007 г. Комитетом ООН по мирному использованию были сформулированы Руководящие принципы Комитета ООН по использованию космического пространства в мирных целях по предупреждению образования космического мусора [62], где основной упор делается на «профилактических мерах», позволяющих свести к минимуму образование мусора при штатной и нештатной эксплуатации космических аппаратов. В части микро- и наноспутников активно обсуждаются различные решения, позволяющие радикально ускорить их сход с орбиты, в том числе – различные электродинамические и «парусные» схемы. Хороший обзор приведен в работе [63].

В целом вопросы специального нормативного правового регулирования сферы создания и применения малых космических аппаратов (в силу их доступности и повышенного «мусорного» потенциала) периодически поднимаются (уже в 2015 г. IASDCC выпустил меморандум, посвященный проблематике создания многоспутниковых прикладных группировок [64]), но в настоящий момент соответствующий международный консенсус еще не сформирован, и прежде всего – в силу двойственного характера самой проблемы, отсутствия общего понимания целесообразности или нецелесообразности ограничений или дополнительного регулирования (включая формирование разрешительного международного режима запусков) «микроспутниковой» деятельности на современном этапе развития космической деятельности в целом. Интересный обзор на эту тему представлен в работе [65].

По мнению российской компании «Лин Индастриал» – разработчика сверхлегкого носителя «Таймыр», – существует три основных причины, по которым дорогие «индивидуальные» запуски могут оказаться предпочтительнее групповых или попутных [66]. Во-первых, при групповых запусках срок запуска полностью определяется графиком готовности основной полезной нагрузки, и малый КА, сколь бы он ни

был ценен, например, для операторов многоспутниковой прикладной системы, как правило, вынужден «ждать у моря погоды». Во-вторых, орбита запуска определяется тоже потребностями основного аппарата. В-третьих, существуют технические ограничения — например, как правило, для попутных запусков не разрешается использовать на малых КА так называемые «высокоэнергетические» устройства — химические ракетные двигатели, пиросредства, баллоны со сжатыми газами. В конечном итоге разработчики сверхмалых ракет сравнивают свои перспективные услуги с услугами такси — по сравнению с перевозками автобусом или троллейбусом, которые, несомненно, дешевле. Отметим, что именно сложившаяся к началу 2010-х гг. ситуация позволяет существовать подобной системе аргументации наряду с обнародованием планов развертывания прикладных микроспутниковых группировок, «ракетный бизнес» стал привлекательным — хотя бы теоретически! — для команд-стартапов и приверженцев «Космоса 2.0». В этом смысле ситуация является в определенном смысле «самораскручивающейся»: микроспутниковые проекты вдохновляют частный бизнес на анонсирование все новых проектов специализированных средств выведения, а инициаторы новых микроспутниковых проектов ссылаются на грядущее радикальное снижение пусковых услуг в том числе и за счет выхода на рынок нынешних «ракетных стартапов». Как положено, в данном случае критерием истины выступит практика — нужно подождать несколько лет.

## 2.11. Основы распознавания пространственно-распределённых целей

Применение сверхширокополосных сигналов и эффекта синтеза апертуры за счёт движения Земли, перемещения космических, воздушных летательных аппаратов позволяет получить радиолокационное изображение (РЛИ) пространственно-распределённой цели (ПРЦ), характеризующееся достаточно высокой разрешающей способностью, при которой наблюдатель имеет возможность решать задачу классификации и распознавания названных ПРЦ.

Проблема классификации радиолокационных изображений ПРЦ, формируемых с помощью таких средств наблюдения, является частной задачей классической теории распознавания образов — ведущего научного направления современного естествознания, сложившегося и интенсивно развивающегося в течение последних десятилетий.

Фундаментальные основы статистической теории распознавания заложены в трудах Т. Андерсона [67], А.А. Харкевича [68], Г.С. Себастиана [69], М.М. Бонгарда [70] и др. Современное состояние этой теории подробно отражено в работах В.Н. Вапника и А.Я. Червоненкиса [71], Р. Дуды и П. Хафа [72], В.А. Ковалевского [73], Дж. Ту и Р. Гонсалеса [74], А.Л. Горелика [75, 76] и других авторов [77, 78].

Пространственно-распределённая цель представляет собой совокупность центров стабильного отражения («блестящих точек») и большого числа статистически однородных отражателей, равномерно распределённых по поверхности цели. В качестве модели последних может быть принята абсолютно шероховатая поверхность, отражения от которой образуют так называемую диффузионную составляющую сигнала.

Количество, положение и ЭПР центров стабильного отражения остаются практически постоянными при изменении ракурса цели на несколько градусов.

Примерами пространственно-распределённых целей могут служить радиолокационные изображения надводных кораблей, полученных космической РЛС с синтезированной апертурой.

На рис. 2.27 представлены РЛИ надводных кораблей для различных условий наблюдения [79, 80] при разрешающей способности РСА – верхний ряд – 15 м и нижний ряд – 35 м; ракурсе наблюдения 283° (А – В), 315° (Г – Е) и 270° (Ж – И); отсутствии качки (А, Г, Ж) и наличии боковой качки 10° на сторону (Б и Д) и 15° на сторону (В и Е), а также при совместном воздействии килевой качки и рысканья  $\pm 7^\circ$  (З, И), где  $R$  – это направление по дальности,  $X$  – направление по азимуту.




Рис. 2.27 Примеры РЛИ ПРЦ (надводных кораблей)

Формулировка существа проблемы заключается в том, чтобы, располагая исходным множеством объектов классификации и заданным априори принципом разделения этого множества на классы, распознающий автомат (РА) в соответствии с оптимальным или близким к нему алгоритмом сформировал из наблюдаемых данных вектор признаков  $L = \{l_1, \dots, l_k\}$  и в соответствии с эффективным решающим правилом разделил пространство признаков таким образом, чтобы, в лучшем случае, с максимальной, а в худшем случае, с заданной вероятностью определить класс очередного обнаруженного объекта. При этом общая постановка задачи классификации объектов радиолокационного наблюдения может быть сформулирована следующим образом.

Пусть задано множество  $B$  объектов различных типов. Система классификации состоит из  $P$  радиолокационных средств, содержащих РА. В каждом из таких РА используется множество радиолокационных сигналов  $S$ , на базе которых образуется множество признаков распознавания и множество правил принятия решения о классе наблюдаемого объекта  $K$ . Кроме того, введем множество параметров  $x$ , связанных с объектом и условиями его наблюдения, причем часть названных параметров  $x$  могут быть измерены РА, а часть параметров  $x_0$  не измеряются в процессе решения задачи классификации, но существенным образом влияют на ее эффективность, которая оценивается с помощью некоторого критерия  $\Xi\{\bullet\}$ .



Если стоимость создания системы классификации  $C$ , а общие ассигнования —  $C_0$ , то формально решение задачи сводится к отысканию экстремума функционала:

$$\exists \{P, S, L, K, x/B\} \quad (2.1)$$

при ограничении

$$C \leq C_0. \quad (2.2)$$

Точные методы решения этой задачи неизвестны, что, вообще говоря, достаточно естественно в связи с чрезвычайно общим характером ее постановки. Разумной альтернативой может служить переход к более частной конкретной задаче с учетом реальных условий, связанных с особенностями решаемой проблемы. При рассматриваемой в работе классификации ПРЦ следует учесть некоторые ограничения, а именно, выраженный статистический характер проблемы, связанный с природой наблюдаемых данных и практической невозможностью решения электродинамической задачи, определяет целесообразность использования вероятностных признаков, отказываясь от детерминированного, логического и структурного подходов [81].

Указанные ограничения определяют методологию подхода к решению задачи классификации ПРЦ. При использовании любого из известных статистических критериев вектор оптимальных признаков  $L$  должен быть образован на основе коэффициентов правдоподобия  $\Delta_j, \Delta_m$  (где  $M$  — число классов) — достаточных статистик, а разбиение пространства решения на области, соответствующие каждому из классов, производится гиперплоскостями (причем, коэффициентами в уравнениях таких плоскостей служат в общем случае элементы матрицы стоимостей).

При полной априорной определенности о распознаваемых классах и условиях наблюдения, а также отсутствии технических ограничений на этом проблема была бы исчерпана. Однако при практическом использовании РА оба названных требования далеки от реальности. В первую очередь это связано с наличием множества мешающих параметров  $\chi$ , которое делится на два подмножества:  $x$  — подмножество принципиально не измеряемых параметров и  $x_0$  — подмножество параметров, оцениваемых по наблюдаемым данным.

Если  $U(t)$  — вектор-функция наблюдаемых данных, то эффективные признаки следует искать, отталкиваясь от коэффициентов правдоподобия:

$$L_{ij} = \frac{P\{U(t)/\bar{x}_0, \bar{x}_i, B_j\}}{P(\bar{U}(t)/B=0)}, \quad (2.3)$$

где  $P\{\cdot\}$  — условный функционал плотности вероятности для реализации  $U(t)$ ;  $x_0$  — вектор оценок измеряемых параметров;  $x_i$  —  $i$ -я комбинация неизвестных параметров;  $B_j$  — указание на наличие цели  $j$ -го класса (при  $B=0$  цель отсутствует).

Следует заметить, что размерность вектора  $L$  становится чрезвычайно большой в связи с континуальным в общем случае характером вектора  $x$ . С другой стороны, при его формировании возникает ряд проблем алгоритмического и технического характера. И, наконец, существующая в современных условиях база данных о радиолокационных портретах (РП) ПРЦ обычно настолько

мала, что не позволяет говорить о достаточно достоверных сведениях о подавляющем большинстве индивидуальных характеристик, конструктивных и геометрических особенностей ПРЦ. Последнее обстоятельство не позволяет получить вектор с составляющими компонентами типа (2.3) и использовать их для классификации.

В связи с этим применяется следующая методология отыскания признаков. Названный вектор ищется на основе выражений для достаточных статистик в предположении о том, что РП и условия наблюдения заданы. После отыскания этих признаков они последовательно модифицируются с тем, чтобы полностью учесть имеющуюся априорную информацию с одновременным отказом от учета тех структурных и алгоритмических особенностей, которые недоступны на этапах проектирования и начальной боевой эксплуатации РА. В тоже время полученные алгоритмы не исключают, а напротив, предусматривают адаптацию к новым данным о РП и условиям наблюдения, полученным при опытной и боевой эксплуатации систем МКРЦ. Аналогичный подход реализуется и по отношению к решающим правилам.

Ряд конкретных решений задачи классификации ПРЦ приведён в работах [82–87].

## 2.12. Литература к главе 2

1. Верба В.С., Неронский Л.Б., Осипов И.Г., Турук В.Э. Радиолокационные системы землеобзора космического базирования/ под ред. В.С. Вербы — М.: Радиотехника, 2010. — 680 с.
2. Официальный сайт японского космического агентства. Миссия ALOS. URL: <https://www.eorc.jaxa.jp/ALOS/en/index.htm> (дата обращения: 29.09.2020).
3. Официальный сайт аргентинского космического агентства. Миссия SAOCOM. URL: <https://www.argentina.gob.ar/ciencia/conae/satellite-saocom-contribucion-argentina-al-sistema-siasge> (дата обращения: 29.09.2020).
4. Дубошин Г.Н. Небесная механика. Основные методы и задачи. — М.: Наука, 1968. — 800 с.
5. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник ALOS. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/a/alos> (дата обращения: 29.09.2020).
6. Lu Zh., Wicks Jr. Ch. Characterizing 6 August 2007 Crandall Canyon mine collapse from ALOS PALSAR InSAR // Geomatics, Natural Hazards and Risk. — 2010. — Vol. 1, № 1. — P. 85–93.
7. Дагаев М.М. Наблюдения звёздного неба. 6-е изд., доп. М.: Наука, 1988. — 176 с.
8. Официальный сайт компании «СКАНЭКС». URL: <http://www.scanex.ru/> (дата обращения: 29.09.2020).
9. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник ALOS-2. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/a/alos-2> (дата обращения: 29.09.2020).
10. Официальный сайт японского космического агентства. Миссия ALOS-3. URL: <https://global.jaxa.jp/projects/sat/alos3/> (дата обращения: 29.09.2020).
11. ГОСТ 24375-80. Радиосвязь. Термины и определения. — М.: Стандартинформ, 2005. — 70 с.

12. Обзор систем землеобзора от европейского космического агентства (ESA). Группировка COSMO-SkyMed. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/c-missions/cosmo-skymed> (дата обращения: 29.09.2020).
13. Большая советская энциклопедия (в 30 т.) / под ред. А.М. Прохорова. — 3-е изд. — М.: Советская энциклопедия, 1969—1978.
14. Описание миссии и продуктов COSMO-SkyMed (Электронное издание [https://www.asi.it/wp-content/uploads/2019/08/COSMO-SkyMed-Mission-and-Products-Description\\_rev3-1.pdf](https://www.asi.it/wp-content/uploads/2019/08/COSMO-SkyMed-Mission-and-Products-Description_rev3-1.pdf)). 2019, вып. 3. — 151 с.
15. Официальный сайт европейского космического агентства. Космический аппарат ERS. URL: <https://earth.esa.int/web/guest/missions/esa-operational-co-missions/ers> (дата обращения: 29.09.2020).
16. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник ERS-1. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/e/ers-1> (дата обращения: 29.09.2020).
17. Официальный сайт европейского космического агентства. Космический аппарат ERS-2. URL: <https://earth.esa.int/web/sppa/mission-performance/esa-missions/ers-2/> (дата обращения: 29.09.2020).
18. Horstmann J., Schiller H., Schulz-Stellenfleth J., Lehner S. Global wind speed retrieval from SAR // IEEE Transactions on geoscience and remote sensing. — 2003. — Vol. 41, № 10. — P. 2277—2286.
19. Astronomical Table of the Sun, Moon and Planets, 3rd edition / ed. J. Meeus. — Richmond: Willmann-Bell, 1995. — 491 p.
20. Официальный сайт мирового центра по сбору данных дистанционного зондирования земной атмосферы. Описание платформы космического аппарата Envisat. URL: <http://wdc.dlr.de/sensors/sciamachy/envisat.php> (дата обращения: 29.09.2020).
21. Официальный сайт сервиса CLOBICE. URL: <http://www.globice.info/Section.php?pid=13> (дата обращения: 29.09.2020).
22. Обзор систем землеобзора от европейского космического агентства (ESA). Группировка спутников RCM. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/r/rcm> (дата обращения: 29.09.2020).
23. Официальный сайт канадского космического агентства. Миссия RADARSAT. URL: <https://www.asc-csa.gc.ca/eng/satellites/radarsat/default.asp> (дата обращения: 29.09.2020).
24. Официальный сайт европейского космического агентства. Космический аппарат RADARSAT-1. URL: <https://earth.esa.int/web/eoportal/satellite-missions/r/radarsat-1> (дата обращения: 29.09.2020).
25. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник RADARSAT-2. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/r/radarsat-2> (дата обращения: 29.09.2020).
26. Описание продуктов RADARSAT-2 (Электронное издание [https://mdacorporation.com/docs/default-source/technical-documents/geospatial-services/52-1238\\_rs2\\_product\\_description.pdf](https://mdacorporation.com/docs/default-source/technical-documents/geospatial-services/52-1238_rs2_product_description.pdf)). 2018, вып. 1/14. — 91 с.
27. Официальный сайт европейского космического агентства. Группировка RCM. URL: <https://earth.esa.int/web/eoportal/satellite-missions/r/rcm> (дата обращения: 29.09.2020).
28. Manore M., DeAbreu R., Zabeline V., Arkett M., Bradley D. The RADARSAT Constellation Mission (RCM): extending operational marine surveillance for environment

Canada // Proceedings of ASTRO 2010, 15th CASI (Canadian Aeronautics and Space Institute) Conference. – 2010. – P.136–141.

29. Официальный сайт миссии Sentinel (ESA). Спутник Sentinel-1. URL: <https://sentinel.esa.int/web/sentinel/missions/sentinel-1> (дата обращения: 29.09.2020).

30. Sentinel-1 data available on AWS and through Sentinel Hub (электронный ресурс <https://medium.com/sentinel-hub/sentinel-1-data-available-on-aws-and-through-sentinel-hub-ecc51c910db6>) (дата обращения: 29.09.2020).

31. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник Sentinel-2. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/c-missions/copernicus-sentinel-2> (дата обращения: 29.09.2020).

32. Официальный сайт миссии Copernicus. Спутник Sentinel-2. URL: <https://www.copernicus.eu/en/media/images/sentinel-2-1> (дата обращения: 29.09.2020).

33. Официальный сайт миссии Sentinel (ESA). Спутник Sentinel-3. URL: <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-3> (дата обращения: 29.09.2020).

34. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник Sentinel-5P. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/c-missions/copernicus-sentinel-5p> (дата обращения: 29.09.2020).

35. Официальный сайт Европейской организации спутниковой метеорологии (EUMETSAT). Цели миссии Sentinel-4. URL: <https://www.eumetsat.int/website/home/Satellites/FutureSatellites/CopernicusSatellites/Sentinel4/index.html> (дата обращения: 29.09.2020).

36. Официальный сайт миссии Sentinel (ESA). Спутник Sentinel-5. URL: <https://sentinel.esa.int/web/sentinel/missions/sentinel-5> (дата обращения: 29.09.2020).

37. Официальный сайт миссии Copernicus. URL: <https://www.copernicus.eu/en> (дата обращения: 29.09.2020).

38. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник TerraSAR-X. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/t/terrasar-x> (дата обращения: 29.09.2020).

39. Описание продуктов TerraSAR-X (Электронное издание [https://www.intelligence-airbusds.com/files/pmedia/public/r459\\_9\\_20171004\\_tsxx-airbusds-ma-0009\\_tsx-productguide\\_i2.01.pdf](https://www.intelligence-airbusds.com/files/pmedia/public/r459_9_20171004_tsxx-airbusds-ma-0009_tsx-productguide_i2.01.pdf)). 2015, вып.2.1. – 24 с.

40. Официальный сайт сервиса GEOCENTO. Коллекция космоснимков спутника TerraSAR-X. URL: <https://geocento.com/satellite-imagery-gallery/terrasar-x/> (дата обращения: 29.09.2020).

41. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник TanDEM-X. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/t/tandem-x> (дата обращения: 29.09.2020).

42. Официальный сайт европейского космического агентства. Спутник TanDEM-X. URL: <https://earth.esa.int/web/eoportal/satellite-missions/t/tandem-x> (дата обращения: 29.09.2020).

43. Официальный сайт компании Airbus. Описание продуктов WorldDEM. URL: <https://www.intelligence-airbusds.com/en/8703-worldddem> (дата обращения: 29.09.2020).

44. Официальный сайт продукта SRTM URL: <http://srtm.csi.cgiar.org/> (дата обращения: 29.09.2020).

45. GIS resources. WorldDEM. URL: <http://www.gisresources.com/reach-accurate-heights-worldtm-dataset/> (дата обращения: 29.09.2020).



46. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник PAZ. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/p/paz> (дата обращения: 29.09.2020).
47. Официальный сайт европейского космического агентства. Спутник PAZ. URL: <https://earth.esa.int/web/eoportal/satellite-missions/p/paz> (дата обращения: 29.09.2020).
48. Обзор систем землеобзора от европейского космического агентства (ESA). Спутник SEOSAT-Ingenio. URL: <https://directory.eoportal.org/web/eoportal/satellite-missions/s/seosat> (дата обращения: 29.09.2020).
49. Баскаков А.И., Лукашенко Ю.И., Щернакова Л.А. Зондирующие радиолокационные сигналы: Учебное пособие / под ред. А.Ф. Богомолова. — М.: Издательство МЭИ, 1990. — 79 с.
50. Анпилогов В.Р. Малые спутники связи на геостационарной орбите — аргументы «за» и «против» // Технологии и средства связи. Специальный выпуск «Спутниковая связь и вещание-2000». — 1999. — № 6-2 [<http://www.vsat-tel.ru/index.php?uid=26&open=1>].
51. Анпилогов В.Р. Малые спутники на ГСО. Обзор и анализ российских проектов // Технологии и средства связи. — 2000. — № 6 [[http://www.vsat-tel.ru/library/art\\_24.htm](http://www.vsat-tel.ru/library/art_24.htm)]
52. Ефремов А.Г. Витер В.В. и др. Малые спутники в сетях связи и вещания // Технологии и средства связи. — 2000. — № 1.
53. Буравин А.Е. Малые спутники связи на геостационарной орбите: ниша и перспективы // Технологии и средства связи. — 2006. — № 3. — С. 82–85.
54. Прохоров Ю.В. Малые спутники на ГСО, Международная конференция VSAT Forum 2006, 25–26 октября 2006 г., Москва.
55. 2016 Nano/Microsatellite Market Forecast. [online]. Доступ через: <http://spaceworksforecast.com>.
56. Анпилогов В.Р. Эффективность низкоорбитальных систем спутниковой связи на основе малых космических аппаратов // Технологии и средства связи. — 2015. — № 4. — С. 62–67.
57. Paul R. Anderson and Lucy Bar-tamian. Growth Trends in Communication Satellites and the Impact on Satellite System Architecture, The Aerospace Corporation, 26th International Communications Satellite Systems Conference (ICSSC). 10–12 June 2008, San Diego, CA, AIAA 2008-5440.
58. Анпилогов В.Р. Спутниковые системы массового обслуживания в Ка-диапазоне // Технологии и средства связи. Специальный выпуск Спутниковая связь и вещание-2011. — 2010. — № 6-2. — Приложение 2. — С. 96–98.
59. Рытенкова О. Развитие новых трендов в области фиксированной спутниковой связи // Технологии и средства связи. — 2015. — № 3. — С. 52–62.
60. Анпилогов В.Р. и др. — Многоспутниковые системы LEO-HTS: «подрывная инновация» в области спутниковой связи или мыльный пузырь? // Технологии и средства связи. Специальный выпуск «Спутниковая связь и вещание-2016». — 2015. — № 6-2. — С. 14–26.
61. Application for Satellite Space Station Authorizations. File Number: SAT LOA 20161115 00118. [online]. Доступ через: [http://licensing.fcc.gov/myibfs/download.do?attachment\\_key=1158354](http://licensing.fcc.gov/myibfs/download.do?attachment_key=1158354).
62. Руководящие принципы Комитета по использованию космического пространства в мирных целях по предупреждению образования космического мусора (2007 г.).

[online]. Доступ через: [http://www.un.org/ru/documents/decl\\_conv/conventions/space\\_de-bris.shtml](http://www.un.org/ru/documents/decl_conv/conventions/space_de-bris.shtml).

63. Трофимов С.П. Увод малых космических аппаратов с низких околоземных орбит: дис. ... канд. физ.-мат. наук: 01.02.01. — М, 2015. С. 125. [online]. Доступ через: <http://keldysh.ru/council/1/2015-trofimov/diss.pdf>.

64. IADC-15-03 February 2016 IADC Statement on Large Constellations of Satellites in Low Earth Orbit. [online]. Доступ через: <http://www.iadc-on-line.org/Documents/IADC-15-3%20Megaconstellation%20State-ment.pdf/>.

65. Kosenkov I., Stelmakh-Drescher O. Capacity-Building of the International Legal Framework for Mitigating Consequences from Non-Operational Small Satellites: Advancing Space Law Towards Newspace Paradigm // A paper for the 67-th International Astronautical Congress. — Guadalajara, Mexico. — September 26–30, 2016. IAC-16, E7,1,6, 33757.

66. Малая РН «Таймыр». [online]. Доступ через: <https://spacelin.ru/proekty/sverkhlegkayaraketa-taymyr/>.

67. Андерсон Т. Введение в многомерный статистический анализ / Т. Андерсон; пер. с англ. Б.В. Гнеденко. М. Физматгиз, 1963. 500 с.

68. Харкевич А.А. Избранные труды. В 3 т. Т. 3. Теория информации. Опознавание образов / А.А. Харкевич. М.: Наука, 1973. 524 с.

69. Себастиан Г.С. Процессы принятия решений при распознавании образов / Г.С. Себастиан; пер. с англ. Ивахненко. Киев: Техника, 1965. 152 с.

70. Бонгард М.М. Проблема узнавания / М.М. Бонгард. М. Наука, 1967. 320 с.

71. Вапник В.Н. Теория распознавания образов (статистические проблемы обучения) / В.Н. Вапник, А.Я. Червоненкис. М.: Наука, 1974. 616 с.

72. Дуда Р. Распознавание образов и анализ сцен / Р. Дуда, П. Харт; пер. с англ. В.Л. Стефанюка. М.: Мир, 1976. 511 с.,

73. Ковалевский В.А. Методы оптимальных решений в распознавании изображений / В.А. Ковалевский. М.: Наука, 1976. 328 с.

74. Ту Дж. Принципы распознавания образов / Дж.Ту, Р.Гонсалес; пер. с англ. М. Журавлева. М.: Мир, 1978. 412 с.

75. Селекция и распознавание на основе локационной информации / под ред. А.Л. Горелик. М. Радио и связь. 1990. 236 с.

76. Горелик А.Л. Методы распознавания / А.Л. Горелик, В.А. Скрипкин. М.: Высшая школа 1984. 208 с.

77. Достовалов М.Ю., Лифанов А.С., Мусинянц Т.Г. Система автоматизированного распознавания объектов на основе исследования радиолокационных портретов по изображениям РСА КОМПАКТ-100. Исследования Земли из космоса, № 1, 2005.

78. Diemunsch J., Wissinger J. MSTAR model-based automatic target recognition: search technology for a robust ATR. Algorithms for Synthetic Aperture Radar Imagery V, E. Zeinio, Eds. // Proceedings of SPIE, Vol.3370, 1998.

79. Каталог изображений Земли. Продукция космического аппарата «Алмаз-1». ОАО «НПО машиностроения». Вэб-сайт <http://almaz1.ru/>

80. Дикинис А.В., Иванов А.Ю., Карлин Л.Н., Неронский Л.Б. и др. Атлас аннотированных радиолокационных изображений морской поверхности, полученных космическим аппаратом «Алмаз — 1». — М.: ГЕОС, 1999.

81. Благовещенский С.Н. Справочник по динамике и статике корабля в 2 т. / С.Н. Благовещенский, А.Н. Холодили. Л.: Судостроение, 1975. т. 2/ 176 с.

82. Доросинский Л.Г. Классификация пространственно-распределенных объектов по данным РЛС бокового обзора / Л.Г. Доросинский, Т.М. Лысенко // Радиотехника 3. 1996. с. 8-12.

83. Доросинский Л.Г. Исследование алгоритмов распознавания радиолокационных изображений распределённых объектов. 23-я Международная Крымская конференция «СВЧ-техника и телекоммуникационные технологии», Севастополь, 8–18 сентября 2013.

84. Доросинский Л.Г. Синтез и анализ алгоритмов классификации радиолокационных сигналов 23-я Международная Крымская конференция «СВЧ-техника и телекоммуникационные технологии», Севастополь, 8–18 сентября 2013.

85. Доросинский Л.Г. Синтез алгоритма распознавания классов радиолокационных сигналов. 24-я Международная Крымская конференция «СВЧ-техника и телекоммуникационные технологии», Севастополь, 7–13 сентября 2014.

86. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА, формируемых в РСА монография. – М.: Издательский дом Академии Естествознания, 2017. 212 с.

87. Доросинский Л.Г., Трухин М.П. Приём и обработка сигналов от сложных целей: монография. – М.: Издательский дом Академии Естествознания, 2018. 264 с.

### 3. КЛАССИФИКАЦИЯ ПРЦ ПО ДАННЫМ КОСМИЧЕСКОЙ РЛС БОКОВОГО ОБЗОРА С СИНТЕЗИРОВАННОЙ АПЕРТУРОЙ

#### 3.1. Математическая модель цели и отражённого сигнала при решении задач распознавания пространственно-распределённых целей в космических РЛС с синтезированной апертурой

Синтез оптимального алгоритма классификации пространственно-распределённых целей (ПРЦ) по данным космического мониторинга земной и/или водной поверхности традиционно начинается с задания математической модели собственно цели и отражённого от неё сигнала. Процесс оптимальной обработки естественным образом содержит в качестве первичного алгоритма процедуру формирования, так называемого, радиолокационного изображений (РЛИ). Названное РЛИ вычисляется в результате сжатия широкополосного импульсного сигнала, обеспечивающего достаточно высокое разрешение по дальности и соответствующее сжатие азимутального сигнала путём когерентного накопления отражённых сигналов вдоль траектории полёта ЛА, реализующего синтез искусственного раскрытия антенны [1].

Основой синтеза является вычисление вектора достаточных статистик — суть отношений правдоподобия относительно ПРЦ каждого из возможных классов. Получение достаточной статистики в первую очередь требует записи математической модели как собственно ПРЦ, так и отражённого от неё сигнала.

Относительное размещение ПРЦ и носителей РСА показано на рис. 3.1, где введены две системы координат: основная неподвижная  $OXYZ$  и вспомогательная  $oxuz$ , связанная с геометрическими осями цели.

Отражающие свойства наблюдаемых ПРЦ описаны комплексной функцией отражения  $f_k^p(\bar{x})$   $k$ -й ПРЦ при наблюдении его  $p$ -ой РЛС. В общем случае считаем, что число РЛС совпадает с числом малых спутников, входящих в группировку, и равно  $P$ . Радиус-вектор элементарного отражающего участка (точки) во вспомогательной системе координат обозначим, как  $\bar{x}$ .

Как показано в [1], функция отражения имеет две независимые составляющие — диффузионную  $f_k^p(\bar{x})$ , связанную с рассеянными отражениями от поверхности цели, и «зеркальную»  $f_{k\sigma}^p(\bar{x})$ , появление которой вызвано наличием зеркально отражающих элементов конструкции и элементов типа угловых отражателей. Эта компонента представляет собой математическую модель физической совокупности центров стабильного отражения, условно именуемых «блестящими точками», в то время как первая составляющая представляет собой непрерывную функцию координат. Из высказанных соображений следует традиционное представление функции отражения в виде следующей формулы:

$$f_k^p(\bar{x}) = f_{k0}^p(\bar{x}) + f_{k\sigma}^p(\bar{x}) = f_{k0}^p(\bar{x}) + \sum_{i=1}^{N_{kp}} f_{ki}^p \delta(\bar{x} - \bar{x}_{ki}^p), \quad (3.1.1),$$

где  $f_{ki}^p$  — значение комплексной функции отражения для  $i$ -й «блестящей точки»  $k$ -й цели при наблюдении ее  $p$ -й РЛС;  $N_{kp}$  — общее число «блестящих точек» при наблюдении цели  $k$ -го класса  $p$ -й РЛС;  $\delta(\bar{x})$  — дельта-функция;  $\bar{x}_{ki}^p$  — радиус-вектор  $i$ -й «блестящей точки».



В общем случае следует иметь в виду, что вид функции отражения  $f_k^p(\bar{x})$  существенным образом зависит от ракурса наблюдения цели, что не отмечено в (3.1.1) для сокращения записи.

При использовании Р РЛС, входящих в группировку малых спутников, объединим функции отражения в  $p$ -компонентный вектор

$$\bar{f}_k(\bar{x}) = \bar{f}_{k0}(\bar{x}) + \bar{f}_{k\sigma}(\bar{x}), \quad (3.1.2),$$

где диффузионная составляющая описывается  $p$ -мерным гауссовским функционалом плотности распределения вероятностей с нулевым вектором средних значений.

Функции отражения соседних элементарных участков поверхности считаем статистически независимыми. При этом матрица взаимных корреляционных функций компонент вектора  $\bar{f}_{k0}(\bar{x})$  может быть представлена в следующем виде:

$$\langle 0,5 \bar{f}_{k0}(\bar{x}) \times \bar{f}_{k0}(\bar{y}) \rangle = \sum_{k0}(\bar{x}) \delta(\bar{x} - \bar{y}). \quad (3.1.3)$$

Матрица  $\sum_{k0}(\bar{x})$  в общем случае является эрмитовой, положительно определенной.




Рис. 3.1. Геометрические соотношения для  $p$ -й РЛС системы

При независимых сигналах РЛС каждого спутника матрица вырождается в вещественную диагональную. Когда сигналы всех РЛС, входящих в группировку, абсолютно когерентны матрица  $\sum_{k0}(\bar{x})$  вырождается в вещественную с равными элементами, что дает возможность представить ее в виде<sup>22</sup>

$$\sum_{k0}(\bar{x}) = \sigma_{k0}^2(\bar{x}) \bar{e}_0 \bar{e}_0^T, \quad (3.1.4)$$

где  $\sigma_{k0}^2(\bar{x})$  – распределение дисперсии диффузионной составляющей функции отражения по поверхности цели  $k$ -го класса;  $\bar{e}_0$  –  $p$ -компонентный вектор-столбец, все элементы которого равны единице.

<sup>22</sup> Такая ситуация принципиально возможна, если спутники настолько близки друг к другу, что отражённые сигналы практически не отличаются друг от друга в разных РЛС.

Для описания статистических свойств отраженных сигналов в литературе, как правило, используются три модели [2]:

- детерминированные отражения;
- для каждой «блестящей точки» амплитуда детерминирована, в то время как фаза случайна и равномерно распределена на интервале  $[-\pi, \pi]$ ;
- для каждой «блестящей точки» отраженный сигнал случаен и подчинен нормальному распределению плотности вероятности с нулевым математическим ожиданием.

При характерном для космических РСА времени наблюдения (менее 1 секунды) диффузионную составляющую можно считать квазидетерминированной, то есть случайной, но не изменяющейся за время наблюдения. Аналогичное предположение может быть высказано относительно функций отражения для «блестящих точек». При этом основным отличием «блестящих точек» от диффузионной составляющей функции отражения является их дискретный характер. Кроме того, суммарная ЭПР «блестящих точек» обычно предполагается много большей ЭПР поверхности цели и составляет до 80 % всей ЭПР цели [3]. Далее предполагаем, что функция отражения нормирована к суммарной ЭПР  $k$ -й цели таким образом, что выполняется равенство:

$$\iint \langle 0,5 \rangle f_k^p(\bar{x}) f_k^{p*}(\bar{y}) d\bar{x} d\bar{y} = 1. \quad (3.1.5)$$

Считая радиолокационные станции для каждого элемента системы наблюдения бистатистическими (передающая РЛС и принимающая РЛС образуют пару, расположенную на двух спутниках), запишем принимаемый сигнал в виде  $p$ -компонентного вектора комплексных амплитуд:

$$\begin{aligned} \bar{U}(t) = U_{kh} \int_{\Omega_k} \dot{f}_k^p(\bar{x}) \frac{g_{1p}(\bar{x}, t) g_{2p}(\bar{x}, t)}{r_{1p}(\bar{x}, t) r_{2p}(\bar{x}, t)} \dot{s}_p \left\{ t - [r_{1p}(\bar{x}, t) + r_{2p}(\bar{x}, t)]/c \right\} \times \\ \times \exp \left\{ -jk_p [r_{1p}(\bar{x}, t) + r_{2p}(\bar{x}, t)] \right\} d\bar{x} + N_p(t), \end{aligned} \quad (3.1.6),$$

где  $g_{1p}(\bar{x}, t)$ ,  $g_{2p}(\bar{x}, t)$  — значения нормированных диаграмм направленности передающей и приемной антенн  $p$ -й РЛС в направлении точки цели  $\bar{x}$  в момент времени  $t$ ;  $r_{1p}(\bar{x}, t)$ ,  $r_{2p}(\bar{x}, t)$  — текущее значение дальности от передатчика и приемника  $p$ -й РЛС до точки  $\bar{x}$  цели;  $s_p(t)$  — комплексная амплитуда модулирующей функции зондирующего сигнала  $p$ -й РЛС, которую в дальнейшем считаем импульсной с длительностью импульса  $\tau_p$  и периодом повторения  $T_p$  и нормированной таким образом, что выполняется условие:

$$\frac{1}{\tau_p} \int |s_p(t)|^2 dt = 1, \quad (3.1.7)$$

где  $N_p t$  — комплексная амплитуда аддитивного шума радиолокационного тракта для  $p$ -й РЛС;  $k_p = 2\pi/\lambda$  — волновое число.

Время наблюдения цели каждой РЛС системы ограничено и равно  $T_{\text{ор}}$ .

С учетом нормировок (3.1.5) и (3.1.7) вещественный множитель  $U_{kp}$  имеет вид [4]:

$$U_{kp} = \sqrt{\frac{2P_{po} \lambda_p^2 G_{1p} G_{2p}}{(4\pi)^3} (\sigma_{ke}^p)^2}, \quad (3.1.8)$$

где  $P_{po}$  — импульсная мощность зондирующего сигнала  $p$ -й РЛС;  $G_{1p}$ ,  $G_{2p}$  — коэффициенты направленного действия (КНД) передающей и приемной антенн  $p$ -й РЛС;  $\sigma_{ke}^p$  — суммарная ЭПР  $k$ -й цели при приеме сигнала  $p$ -й РЛС.

Введем диагональные матрицы размерности  $p \times p$ :

$$\begin{aligned} G(\bar{x}, t) &= \text{diag} [G_1(\bar{x}, t), G_2(\bar{x}, t), \dots, G_p(\bar{x}, t)]; \\ S(\bar{x}, t) &= \text{diag} [S_1(\bar{x}, t), S_2(\bar{x}, t), \dots, S_p(\bar{x}, t)]; \\ E(\bar{x}, t) &= \text{diag} [E_1(\bar{x}, t), E_2(\bar{x}, t), \dots, E_p(\bar{x}, t)]; \\ U_k &= \text{diag} [U_{k1}, U_{k2}, \dots, U_{kp}]; \end{aligned} \quad (3.1.9)$$

$$G_p(\bar{x}, t) = \frac{g_{1p}(\bar{x}, t) g_{lp}(\bar{x}, t)}{r_{1p}(\bar{x}, t) r_{lp}(\bar{x}, t)}; \quad (3.1.10)$$

$$S_p(\bar{x}, t) = s_p \left\{ t - [r_{1p}(\bar{x}, t) + r_{2p}(\bar{x}, t)] / c \right\}; \quad (3.1.11)$$

$$E_p(\bar{x}, t) = \exp \left\{ -jk_p [r_{1p}(\bar{x}, t) + r_{2p}(\bar{x}, t)] / c \right\}. \quad (3.1.12)$$

Используя (2.1.2), вектор комплексных амплитуд представим в виде суммы:

$$\bar{U}(t) = \bar{U}_{k0}(t) + \bar{U}_{k\sigma}(t) + \bar{N}(t), \quad (3.1.13)$$

где

$$\bar{U}_{k0}(t) = U_k \int G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) f_{k0}(\bar{x}) d\bar{x}; \quad (3.1.14)$$

$$\bar{U}_{k\sigma}(t) = U_k \int G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) f_{k\sigma}(\bar{x}) d\bar{x}; \quad (3.1.15)$$

$$N(t) = \{N_1(t), N_2(t), \dots, N_p(t)\}. \quad (3.1.16)$$

Компоненты шума (3.1.16) будем считать гауссовскими белыми и статистически независимыми между собой. Вектор  $N(t)$  учитывает, как шумы приемников радиолокационных станций, так и сигналы, отраженные статистически однородной подстилающей поверхностью.

Из (3.1.6) следует, что для полного описания принимаемых сигналов необходимо в явном виде знать зависимость дальностей  $r_1$  и  $r_2$  от координат отражающей точки и текущего времени.

На рис. 3.1 движения носителей передающей (Прд.р) и приемной (Прм.р) частей  $p$ -й РЛС описываются в основной системе координат  $OXYZ$  радиус-векторами  $\bar{r}_1^p(t)$  и  $\bar{r}_2^p(t)$ . Движение центра масс наблюдаемой цели характеризуется радиус-вектором  $r(t)$ . Для описания движения произвольной точки  $\bar{x}$  цели относительно центра масс в основной системе координат используем вектор  $\bar{\rho}_p(\bar{x}, t)$ . В произвольный момент времени  $t$  связь векторов  $\bar{\rho}_p(\bar{x}, t)$  и  $\bar{x}$  задается выражением [1]:

$$\bar{\rho}_p(\bar{x}, t_i) = A_p(t_i) \bar{x}, \quad (3.1.17)$$

где  $A_p(t_i)$  — матрица поворота осей вспомогательной системы координат относительно основной системы  $OXYZ$  в момент  $t_i$ .

Без учета смещения носителей приемной и передающей частей РЛС за время распространения сигнала до цели и обратно искомые зависимости описываются выражениями:

$$r_{1p}(\bar{x}, t) = |\bar{r}_{0p}(t) + \bar{\rho}_p(\bar{x}, t) - \bar{r}_1^p(t)|; \quad (3.1.18)$$

$$r_{2p}(\bar{x}, t) = |\bar{r}_{0p}(t) + \bar{\rho}_p(\bar{x}, t) - \bar{r}_2^p(t)|. \quad (3.1.19)$$

Поскольку формулы (3.1.18) и (3.1.19) отличаются только индексами, то дальнейшие выкладки выполнены лишь для первой из них.

Разложим (3.1.18) в ряд Тейлора в окрестности точки  $t_{0p}$ , соответствующей середине интервала наблюдения цели  $p$ -й РЛС

$$r_{1p}(\bar{x}, t) = r_{1p}(\bar{x}, t_{0p}) + \sum_{i=1}^{\infty} \frac{1}{i!} r_{1p}^{(i)}(\bar{x}, t_{0p}) \cdot (t - t_{0p})^i, \quad (3.1.20)$$

где  $r_{1p}^{(i)}(\bar{x}, t_{0p})$  — значение  $i$ -й производной функции  $r_{1p}(\bar{x}, t)$  по времени в момент  $t = t_{0p}$ .

Используя правила дифференцирования векторов и их модулей, получим выражения для первых четырех производных:

$$r_{1p}^{(1)}(\bar{x}, t_{0p}) = \bar{e}_{1p}^{(1)}(\bar{x}, t_{0p}) \cdot \bar{v}_{1p}^{(1)}(\bar{x}, t_{0p}); \quad (3.1.21)$$

$$r_{1p}^{(2)}(\bar{x}, t_{0p}) = \frac{|\bar{v}_{1p}(\bar{x}, t_{0p})|^2 - |r_{1p}^{(1)}(\bar{x}, t_{0p})|^2}{|r_{1p}(\bar{x}, t_{0p})|} + \bar{e}_{1p}(\bar{x}, t_{0p}) \cdot \bar{A}_{1p}(\bar{x}, t_{0p}); \quad (3.1.22)$$

$$r_{1p}^{(3)}(\bar{x}, t_{0p}) = 3 \frac{\bar{v}_{1p}(\bar{x}, t_{0p}) \cdot \bar{A}_{1p}(\bar{x}, t_{0p}) - r_{1p}^{(1)}(\bar{x}, t_{0p}) \cdot r_{1p}^{(2)}(\bar{x}, t_{0p})}{|r_{1p}(\bar{x}, t_{0p})|} + \bar{e}_{1p}(\bar{x}, t_{0p}) \cdot \bar{W}_{1p}(\bar{x}, t_{0p}); \quad (3.1.23)$$

$$r_{1p}^{(4)}(\bar{x}, t_{0p}) = 3 \frac{|\bar{A}_{1p}(\bar{x}, t_{0p})|^2 - |r_{1p}^{(2)}(\bar{x}, t_{0p})|^2}{|r_{1p}(\bar{x}, t_{0p})|} + 4 \frac{\bar{v}_{1p}(\bar{x}, t_{0p}) \cdot \bar{W}_{1p}(\bar{x}, t_{0p}) - r_{1p}^{(1)}(\bar{x}, t_{0p}) \cdot r_{1p}^{(3)}(\bar{x}, t_{0p})}{|r_{1p}(\bar{x}, t_{0p})|} + \bar{e}_{1p}(\bar{x}, t_{0p}) \cdot \bar{B}_{1p}(\bar{x}, t_{0p}); \quad (3.1.24)$$

$$\bar{e}_{1p}(x, t_{0p}) = \frac{\bar{r}_{0p}(t_{0p}) + \bar{\rho}_p(\bar{x}, t_{0p}) - \bar{r}_1^p(t_{0p})}{|\bar{r}_{0p}(t_{0p}) + \bar{\rho}_p(\bar{x}, t_{0p}) - \bar{r}_1^p(t_{0p})|} \quad (3.1.25)$$

— единичный вектор визирования точки  $\bar{x}$  в момент времени  $t$ ,

$$\bar{V}_{1p}(x, t) = \frac{d}{dt} [\bar{r}_{0p}(t) + \bar{\rho}_p(\bar{x}, t) - \bar{r}_1^p(t)]; \quad (3.1.26)$$

$$\bar{A}_{1p}(\bar{x}, t) = \frac{d}{dt} [\bar{V}_{1p}(x, t)]; \quad (3.1.27)$$

$$\bar{W}_{1p}(\bar{x}, t) = \frac{d}{dt} [\bar{A}_{1p}(x, t)]; \quad (3.1.28)$$

$$\bar{B}_{1p}(\bar{x}, t) = \frac{d}{dt} [\bar{W}_{1p}(x, t)]. \quad (3.1.29)$$

Полученные соотношения достаточно компактны и при наличии данных о параметрах траекторий движения носителей РЛС и цели могут быть использованы для решения задач синтеза и анализа алгоритмов обнаружения, измерения параметров и классификации ПРЦ.



### 3.2. Многоальтернативная проверка гипотез относительно различных классов ПРЦ при их наблюдении совокупностью космических радиолокационных средств

Определим класс наблюдаемой ПРЦ методом максимального правдоподобия. Для этого запишем условную плотность вероятности наблюдать вектор  $\bar{U}(t)$  при наличии ПРЦ  $k$ -го класса. Общее число возможных классов считаем равным  $M$ , Гипотеза с номером  $(M + 1)$  соответствует наблюдению только фона (ПРЦ отсутствует).

При точно известных параметрах, характеризующих условия наблюдения, оптимальная обработка сводится к вычислению отношений правдоподобия для всех  $M$  гипотез  $l_k[\bar{U}(t)] = \ln \{L_k[\bar{U}(t)]\}$  и выбора того номера  $k$ , при котором  $l_k[\bar{U}(t)]$  максимально.

Достаточная статистика для принятия решения представляет собой вектор, составленный из отношений правдоподобия для каждой из  $M$  конкурирующих гипотез. Логарифм отношения правдоподобия для  $k$ -й гипотезы при отсутствии флуктуаций сигналов, отраженных «блестящими точками», может быть записан в виде [6]:

$$l_k[\bar{U}(t)] = \left\{ 0,5 \iint \bar{U}^*(t) Q_0(t, u) \bar{U}(u) dt du - \right. \\ \left. - \iint [\bar{U}^*(t) - \bar{U}_{k\sigma}^*(t)] Q_k(t, u) [\bar{U}(u) - \bar{U}_{k\sigma}(u)] dt du - \ln \left( \frac{K_0}{K_k} \right) \right\}, \quad (3.2.1)$$

где  $K_0$  и  $K_k$  — нормирующие коэффициенты функционалов плотности распределения вероятностей для случаев наблюдения только шума и  $k$ -й цели на фоне шума;  $Q_0(t, u)$ ,  $Q_k(t, u)$  — комплексные матрицы, обратные матрицам взаимной корреляции принимаемого вектора  $\bar{U}(t)$  для гипотез о наблюдении только шума  $R(t, u)$  и  $k$ -й цели на фоне шума  $R_k(t, u)$ .

Поскольку шум и диффузионная составляющая принимаемого сигнала  $\bar{U}_{k0}(t)$  являются независимыми случайными процессами, то

$$R_k(t, u) = R_{k0}(t, u) + R_0(t, u), \quad (3.2.2)$$

$$\text{где} \quad R_{k0}(t, u) = 0,5 \bar{U}_{k\sigma}(t) + \bar{U}_{k\sigma}^*(u) \quad (3.2.3)$$

— матрица корреляционных функций диффузионных составляющих вектора принимаемого сигнала.

Для определения вида матриц  $Q_0(t, u)$  и  $Q_k(t, u)$  следует воспользоваться интегрально-матричными уравнениями обращения:

$$\int R_0(t, u) Q_0(u, v) du = I \delta(t - v); \quad (3.2.4)$$

$$\int R_k(t, u) Q_k(u, v) du = I \delta(t - v), \quad (3.2.5)$$

где  $I$  — единичная диагональная матрица.

Для последнего слагаемого в (3.2.1) справедливо равенство:

$$\ln \left( \frac{K_0}{K_k} \right) = Sp \int_0^1 \frac{dA}{A} \iint R_0(t, u) Q_{Ak}(u, t) dt du, \quad (3.2.6)$$

где  $Q_{Ak}(u, t)$  — решение интегрально-матричного уравнения:

$$\iint [R_0(t_1, u) + AR_{k0}(t_1, u)] Q_{Ak}(u, v) R_0(v, t_2) dv = AR_{k0}(t_1, t_2). \quad (3.2.7)$$

При условии, что шум радиолокационного тракта «белый» с диагональной матрицей спектральных плотностей  $N_0$  выражения (3.2.4)–(3.2.7) упрощаются:

$$Q_0(t, u) = N_0^{-1} \delta(t, u); \quad (3.2.8)$$

$$\int R_{k0}(t, u) Q_k(u, v) du + N_0 Q_k(t, v) = I \delta(t - v); \quad (3.2.9)$$

$$\ln \left( \frac{K_0}{K_k} \right) = Sp \int \frac{dA}{A} \int N_0 Q_{Ak}(t, t) dt; \quad (3.2.10)$$

$$N_0 Q_{Ak}(t, v) N_0 + A \int R_{k0}(t, u) Q_{Ak}(u, v) N_0 du = A R_{k0}(t, v). \quad (3.2.11)$$

Пользуясь рекомендациями [6], ищем матрицу  $Q_k(t, u)$  в виде

$$Q_k(t, u) = N_0^{-1} [I \delta(t - u) - Q_{k0}(t, u)]. \quad (3.2.12)$$

В этом случае равенство (2.9) преобразуется следующим образом:

$$\int R_{k0}(t, u) N_0^{-1} Q_{k0}(u, v) du + Q_{k0}(t, v) = R_{k0}(t, v) N_0^{-1}. \quad (3.2.13)$$

Сравнение (2.2.11) с (2.2.13) показывает, что матрица  $Q_{k0}(t, u)$  может быть найдена путем решения (2.2.11) при  $A = 1$ , т. е.

$$Q_{k0}(t, u) = N_0 Q_{Ak}(t, u)_{|A=1}. \quad (3.2.14)$$

Подставляя (2.2.8) в (2.2.1), получим:

$$\begin{aligned} I_k [\bar{U}(t)] = 0,5 \left\{ \iint [\bar{U}^*(t) - \bar{U}_{k\sigma}^*(t)] N_0^{-1} Q_{k0}(t, u) \times \right. \\ \times [\bar{U}(u) - \bar{U}_{k\sigma}(u)] dt du - \int \bar{U}_{k\sigma}^*(t) N_0^{-1} \bar{U}_{k\sigma}(t) dt + \\ \left. + 2 \operatorname{Re} \left[ \int \bar{U}_{k\sigma}^*(t) N_0^{-1} \bar{U}(t) dt \right] - \ln \left( \frac{K_0}{K_k} \right) \right\}. \end{aligned} \quad (3.2.15)$$

Из (3.2.15) и рис. 3.2 следует, что алгоритм формирования отношения правдоподобия  $I_k[\bar{U}(t)]$  содержит два канала. В первом из них вычисляется корреляция принимаемой реализации вектора  $\bar{U}(t)$ , нормированного к мощности шумов, с вектором ожидаемого сигнала, порожденного «блестящими точками»  $k$ -й цели  $\bar{U}_{k\sigma}(t)$ . Во втором канале разностный сигнал  $\bar{U}(t) - \bar{U}_{k\sigma}(t)$  коррелируется с вектором

$$\int Q_{k0}(t, u) [\bar{U}(u) - \bar{U}_{k\sigma}(u)] du,$$

который представляет собой оценку диффузионной составляющей принимаемого сигнала в предположении о наблюдении  $k$ -й цели.

Дальнейшая конкретизация алгоритма формирования логарифма отношения правдоподобия и структуры реализующего его устройства возможна лишь при определении матриц  $Q_{Ak}(t, u)$  и  $Q_{k0}(t, u)$ , для чего необходимо решить уравнение (3.2.11).

Прежде всего выясним вид корреляционной функции  $R_{k0}(t, u)$ . Используя (3.2.14) и (3.2.3), получим:

$$\begin{aligned} R_{k0}(t, u) &= 0,5 \bar{U}_{k\sigma}(t) + \bar{U}_{k\sigma}^*(u) = \\ &= \int_{\Omega_k} U_k G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) \sum_{k0} (\bar{x}) E^*(\bar{x}, t) S^*(\bar{x}, t) G(\bar{x}, t) U_k d\bar{x}. \end{aligned} \quad (3.2.16)$$

Воспользовавшись широко известным приемом [7], будем искать  $Q_{Ak}(t, u)$  в виде, аналогичном (3.2.16):

$$\begin{aligned} Q_{Ak}(t, u) &= \iint_{\Omega_k} N_0^{-1} U_k G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) H_{Ak}(\bar{x}, \bar{y}) \times \\ &\times E^*(\bar{y}, u) S^*(\bar{y}, u) G^*(\bar{y}, u) U_k N_0^{-1} d\bar{x} d\bar{y}. \end{aligned} \quad (3.2.17)$$

После подстановки (3.2.16, 3.2.17) уравнение (3.2.11) может быть представлено в виде

$$\begin{aligned} H_{Ak}(\bar{x}, \bar{y}) + A \sum_{k0} (\bar{x}) U_k N_0^{-1} U_k \int \Psi^0(\bar{x}, \bar{z}) H_{Ak}(\bar{x}, \bar{z}) d\bar{z} = \\ = A \sum_{k0} (\bar{x}) \delta(\bar{x} - \bar{y}), \end{aligned} \quad (3.2.18)$$

где введена матрица ( $p \times p$ )

$$\Psi^0(\bar{x}, \bar{z}) = \int E^*(\bar{x}, u) S^*(\bar{x}, u) G^*(\bar{x}, u) G(\bar{z}, u) S(\bar{z}, u) E(\bar{z}, u) du. \quad (3.2.19)$$

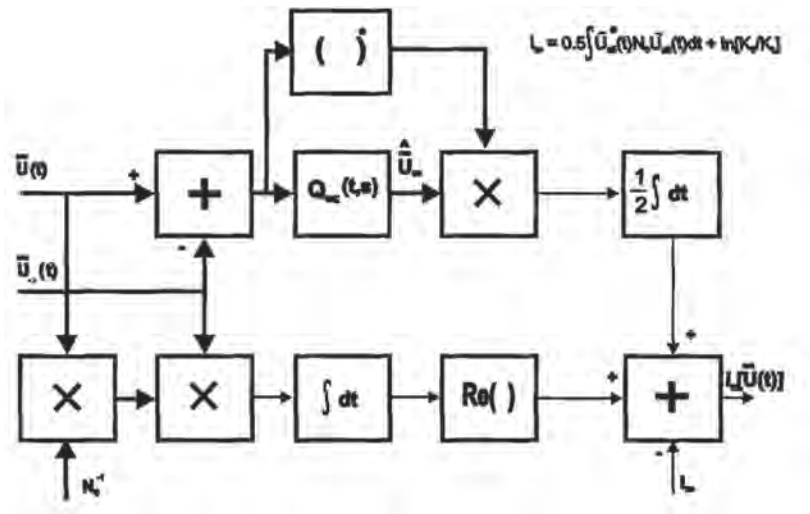


Рис. 3.2. Вариант структурной схемы устройства формирования логарифма отношения правдоподобия

Подстановка (2.2.17) в (2.2.15) дает следующий результат:

$$\begin{aligned} I_k[\bar{U}(t)] &= 0,5 \left\{ \iint_{\Omega_k} [\bar{F}^*(\bar{x}) - \bar{F}_{k\sigma}^*(\bar{x})] N_0^{-1} U_k H_{k0}(\bar{x}, \bar{y}) U_k N_0^{-1} \times \right. \\ &\times [\bar{F}^*(\bar{y}) - \bar{F}_{k\sigma}^*(\bar{y})] d\bar{x} d\bar{y} + 2 \operatorname{Re} \left[ \int \bar{U}_{k\sigma}^*(t) N_0^{-1} \bar{U}(t) dt \right] - \\ &\left. - \int \bar{U}_{k\sigma}^*(t) N_0^{-1} \bar{U}_{k\sigma}(t) dt - \ln \left( \frac{K_0}{K_k} \right) \right\}; \end{aligned} \quad (3.2.20)$$

$$H_{k0}(\bar{x}, \bar{y}) = H_{Ak}(\bar{x}, \bar{y})_{|A=1|}; \quad (3.2.21)$$

$$ESG(\bar{x}, u) = E(\bar{x}, u)S(\bar{x}, u)G(\bar{x}, u). \quad (3.2.22)$$

Используя (3.2.15), преобразуем второе и третье слагаемые в фигурных скобках (3.2.20). В результате получим:

$$I_k[\bar{U}(t)] = 0,5 \left\{ \iint_{\Omega_k} [\bar{F}^*(x) - \bar{F}_{k\sigma}^*(x)] N_0^{-1} U_k H_{k0}(\bar{x}, \bar{y}) U_k N_0^{-1} \times \right. \\ \left. \times [\bar{F}(\bar{y}) - \bar{F}_{k\sigma}(\bar{y})] d\bar{x} d\bar{y} + 2 \operatorname{Re} \left[ \int \bar{f}_{k\sigma}^*(\bar{x}) U_k N_0^{-1} \bar{F}(\bar{x}) d\bar{x} \right] \right\}. \quad (3.2.23)$$

Кратко рассмотрим смысл введенных функций  $\Psi^0(\bar{x}, \bar{z})$ ,  $\bar{F}(\bar{x})$  и  $\bar{F}_{k\sigma}(\bar{x})$ .

Рассмотрим  $p$ -ю компоненту вектора  $\bar{F}(\bar{x})$ . При отсутствии шума с учетом (3.2.6) имеем:

$$\bar{F}_p(x) = U_{kp} \int_{\Omega_k} \Psi_p^0(\bar{x}, \bar{z}) f_k^p(\bar{z}) d\bar{z}. \quad (3.2.24)$$

Оптимальный алгоритм обработки представлен на рис. 3.3. Для выяснения физического смысла интеграла

$$\int H_{k0}(\bar{x}, \bar{y}) U_k N_0^{-1} [\bar{F}(\bar{y}) - \bar{F}_{k\sigma}(\bar{y})] d\bar{y}$$

умножим его слева на

$$U_k G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t)$$

и проинтегрируем результат по  $\bar{x}$ . Учитывая (3.2.14) и (3.2.17), получим:

$$U_k G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) \int H_{k0}(\bar{x}, \bar{y}) U_k N_0^{-1} [\bar{F}(\bar{y}) - \bar{F}_{k\sigma}(\bar{y})] d\bar{y} = \\ = \int Q_{k0}(t, u) [\bar{U}(u) - \bar{U}_{k\sigma}(u)] du. \quad (3.2.25)$$

Как уже отмечалось, правая часть (3.2.25) представляет собой оценку диффузионной составляющей принимаемого сигнала в предположении о наблюдении  $k$ -й цели. Используя (3.2.14), представим эту оценку в виде:

$$U_{k0}^\epsilon(t) = U_k \int G(\bar{x}, t) S(\bar{x}, t) E(\bar{x}, t) f_{k\sigma}^\epsilon(\bar{x}) d\bar{x} \quad (3.2.26)$$

составляющей функции отражения  $k$ -й цели по координатам. Сравнение (3.2.25) и (3.2.26) приводит к следующему результату:

$$\int H_{k0}(\bar{x}, \bar{y}) U_k N_0^{-1} [\bar{F}(\bar{y}) - \bar{F}_{k\sigma}(\bar{y})] d\bar{y} = f_{k\sigma}^\epsilon(\bar{x}). \quad (3.2.27)$$

Полученный интеграл представляет собой оптимальную оценку диффузионной составляющей функции отражения ПРЦ в предположении о том, что справедлива  $k$ -я гипотеза.

Из выполненного синтеза следует, что необходимая для принятия решения информация содержится в комплексных РЛИ наблюдаемых целей. При этом обработка изображения заключается в вычислении корреляций его с детерминированной функцией отражения «блестящих точек»  $k$ -й цели  $\hat{f}_{k\sigma}(\bar{x})$  и оценкой диффузионной составляющей  $\bar{f}_p(\bar{x})$ .



Получение полной информации, необходимой для реализации оптимального алгоритма, требует чрезвычайно большого объема наблюдаемых данных для формирования достоверного «радиолокационного портрета» и практически недостижимо в обозримом будущем, что приводит к необходимости разработки алгоритмов, требующих для своей реализации ограниченного объема априорной информации, с одной стороны, достаточно информативных, и, с другой стороны, доступных сравнительно неложными средствами

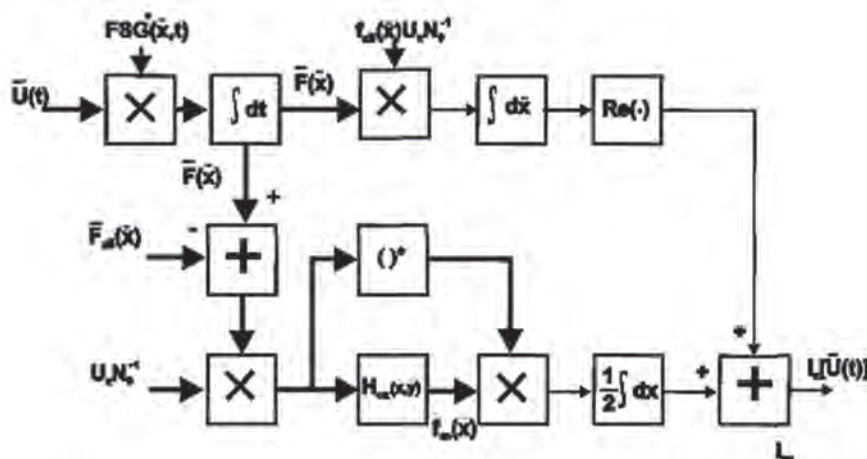


Рис. 3.3. Вариант структурной схемы устройства формирования логарифма отношения правдоподобия

К устойчивым и достоверным сведениям о различиях распознаваемых пространственно-распределённых целей могут быть отнесены:

- а) данные о различиях в размерах (длине и ширине);
- б) данные о различиях в интегральной (общей) ЭПР.

Практически реализуемый «рабочий» алгоритм формирования статистик принятия решения не должен использовать индивидуальные радиолокационные портреты (распределения ЭПР «блестящих точек» и диффузионной составляющей по поверхности цели). Считая распределение ЭПР равномерным, приходим к следующему выражению статистики, которая составляет основу принятия решения по любому статистическому критерию

$$I_k = \int_{\Omega_k(j)} |F(\bar{x})|^2 d\bar{x}, \quad (3.2.28)$$

где подчеркнута зависимость области, занятой целью  $k$ -го класса от ракурса его наблюдения  $\varphi$ .

### 3.3. Адаптивный алгоритм классификации пространственно-распределённых целей по данным радиолокатора с синтезированной апертурой

Не изменяя общей методологии решения задачи классификации, ограничимся примером распознавания 3 классов ПРЦ.

Вывод алгоритма произведем при следующих предположениях:

1. РСА перемещается по прямолинейной траектории, использует импульсный широкополосный зондирующий сигнал, причем отсчеты РЛИ различных каналов дальности

могут считаться статистически независимыми. В связи с этим все дальнейшие рассуждения проводятся для одного канала дальности. Обобщение алгоритма на всё РЛИ производится естественным образом на заключительном этапе вывода алгоритма классификации.

2. Весь участок поверхности, попадающий в один канал дальности, разбит на отдельные элементарные участки, состоящие, в свою очередь, из большого числа элементарных отражателей. Каждый элементарный участок определяется своей координатой  $x_i$  ( $i = 1, \overline{I}$ ;  $I$  – общее число таких участков, расположенных в раскрыве реальной диаграммы направленности). Сигнал, отраженный от такого участка, представляет собой нормальный случайный процесс с нулевым математическим ожиданием и дисперсией  $\sigma_m^2(x_i)$ , которая зависит от целого ряда параметров, в первую очередь, от типа объекта, его индивидуальных особенностей, а также условий наблюдения. При обозначении мощности отраженного сигнала сохранен индекс « $m$ », характеризующий ее зависимость от номера класса объекта. Названная функция как раз и является той зависимостью, значения которой отличают один класс наблюдаемой ПРЦ от другого (лес от поля, дорога от пашни и т. п.). Основные геометрические соотношения показаны на рис. 3.4.




Рис. 3.4. Геометрия задачи

3. Сигналы, отраженные различными элементарными участками поверхности, созданы физически различными отражателями и поэтому с достаточным основанием могут считаться статистически независимыми.

4. Вектор признаков, используемых для классификации (размерность вектора совпадает с числом классов), представляет собой вектор достаточных статистик (отношений правдоподобия) или его модификации, применение которых связано с недостаточной априорной информацией о характеристиках наблюдаемых поверхностей.

С учетом принятых предположений комплексная амплитуда сигнала, принимаемого в  $n$ -й точке траектории от  $i$ -го элементарного участка поверхности с координатой  $x_i$  может быть записана в следующем виде:

$$U_n = \sum_{i=1}^I f_n^m(x_i) \exp(-j\varpi_0 \tau_n(x_i)) + N_n, \quad (3.3.1)$$

где  $\varpi_0$  – несущая частота;  $\tau_n(x_i)$  – запаздывание сигнала, принимаемого в  $n$ -й точке траектории от  $i$ -го элементарного участка наблюдаемой поверхности;  $f_n^m(x_i)$  – комплексная амплитуда сигнала, формируемого  $i$ -м элементарным участком поверхности

объекта  $m$ -го класса в  $n$ -й точке приема;  $N_n$  — комплексная амплитуда  $n$ -го отсчёта шума. Комплексная амплитуда (3.3.1) представляет собой выборочное значение нормальной случайной величины, имеющей следующие статистические характеристики:

$$M\{f_n^m(x_i)\} = 0; \quad (3.3.2)$$

$$M\{f_n^m(x_i)f_n^m(x_j)\} = \sigma_m^2(x_i)\delta_{ij}, \quad (3.3.3)$$

где  $\delta_{ij}$  — символ Кронеккера;  $\sigma_m^2(x_i)$  — удельная ЭПР  $m$ -го класса ПРЦ как функция от координат поверхности.

Обозначая расстояние до центра наблюдаемого участка поверхности  $R_H$ , запишем величину запаздывания отраженного сигнала от  $i$ -го элементарного участка до  $n$ -й точки траектории:

$$\tau_n(x_i) = \frac{2}{C}\sqrt{R_H^2 + (r_n - x_i)^2} \approx \frac{2R_H}{C}\left[1 + \frac{(r_n - x_i)^2}{2R_H^2}\right], \quad (3.3.4)$$

где  $C$  — скорость света;  $r_n$  — координата  $n$ -й точки приема отраженного сигнала.

Обобщая высказанные предположения, сформируем вектор наблюдаемых данных на выходе приемника локатора:

$$U = \beta f^k + N_{\text{ш}}, \quad (3.3.5)$$

где  $\beta = (S(x_1), \dots, S(x_I))$  — матрица ( $N_{\text{ш}} \times I$ ), состоящая из векторов:

$$S(x_i) = \|S(x_i^n)\| = \left\| \exp\left(j\frac{2\pi}{\lambda R_H}r_n^2 - j\frac{4\pi}{\lambda R_H}x_i r_n\right) \right\|, \quad (3.3.6)$$

задающих фазовое распределение сигнала, отраженного от  $i$ -го элемента поверхности, по точкам синтезируемой апертуры, имеющим координаты  $r_n$   $n=1, N_{\text{ш}}$ ;  $N_{\text{ш}}$  — число принимаемых импульсов;  $f^k = \|f_i^k\| = \|f_n^k(x_i)\|$  — вектор комплексных амплитуд, размерность которого определяется числом отражающих элементарных участков поверхности;  $N_{\text{ш}}$  — вектор отсчетов шума, имеющего следующие статистические характеристики:

$$M\{N_{\text{ш}}\} = 0; 0,5M\{N_{\text{ш}}N_{\text{ш}}^{*T}\} = R_{\text{ш}} = \sigma_{\text{ш}}^2 E,$$

где  $E$  — единичная матрица, а  $\sigma_{\text{ш}}^2$  — дисперсия шума.

Для решения задачи классификации по какому-либо из статистических критериев: минимума среднего риска, максимума апостериорной плотности или максимального правдоподобия (этот критерий в дальнейшем будет принят в качестве основного) — необходимо записать отношение правдоподобия:

$$\Delta_K = \frac{P(U/\text{сигнал от цели } m\text{-го класса} + \text{шум})}{P(U/\text{шум})}, \quad (3.3.7)$$

где  $P[U/.]$  — условная плотность вероятности наблюдения вектора  $U$  при наличии поверхности  $m$ -го класса и шума или только шума. Считая вектор  $U$  гауссовским

с нулевым математическим ожиданием, что соответствует предыдущим рассуждениям, запишем отношение правдоподобия:

$$\Lambda_k = \frac{1}{|E + \beta Q_k \beta^{*T}|} \exp\left(-0,5 U^{*T} [R_{\text{ш}}^{-1} - R_{\text{CШ}_m}^{-1}] U\right), \quad (3.3.8)$$

где  $R_{\text{CШ}_m} = \beta Q_m \beta^{*T} + R_{\text{ш}}, \quad (3.3.9)$

$$Q_m = \begin{pmatrix} \sigma_{1m}^2 & & 0 \\ & \ddots & \\ 0 & & \sigma_{lm}^2 \end{pmatrix}$$

— матрица мощностей сигналов от каждого из  $I$  элементарных участков, входящих в анализируемую поверхность  $m$ -го класса.

Учитывая специальный вид матрицы (3.3.9) и используя равенство Вудбери, запишем логарифм отношения правдоподобия в следующем виде:

$$l_m = \ln \Lambda_m = 0,5 U^{*T} R_{\text{ш}}^{-1} \beta [E + Q_m \beta^{*T} R_{\text{ш}}^{-1} \beta]^{-1} Q_m \beta^{*T} R_{\text{ш}}^{-1} U - Sp \ln(E + \beta Q_m \beta^{*T}). \quad (3.3.10)$$

Здесь

$$Q_k = \begin{pmatrix} \sigma_{1m}^2 / \sigma_{\text{ш}}^2 & & 0 \\ & \ddots & \\ 0 & & \sigma_{lm}^2 / \sigma_{\text{ш}}^2 \end{pmatrix}^{-1} = \begin{pmatrix} q_m & & 0 \\ & \ddots & \\ 0 & & q_{lm} \end{pmatrix} \quad (3.3.11)$$

— диагональная матрица отношений мощностей сигналов от каждого  $i$ -го элементарного участка к мощности шума в одном импульсе.

Вводя новый вектор

$$F = \|F_i\| = \frac{1}{\sigma_{\text{ш}}} \beta^{*T} R_{\text{ш}}^{-1} U = \left\| \frac{1}{\sigma_{\text{ш}}} \sum_{n=1}^{N_{\text{и}}} U_n \exp\left(-j \frac{2\pi}{\lambda R_H} r_n^2 + j \frac{4\pi}{\lambda R_H} r_n x_i\right) \right\|, \quad (3.3.12)$$

компоненты которого представляют собой отсчеты комплексных амплитуд РЛИ, для достаточной статистики (логарифма отношения правдоподобия) получаем выражение:

$$l_m = \ln \Lambda_m = 0,5 F^{*T} (E + Q_m \beta^{*T} \beta)^{-1} Q_m F - Sp \ln(E + \beta Q_m \beta^{*T}). \quad (3.3.13)$$

Считая размер элементарного участка поверхности равным размеру элемента разрешения по азимуту и пренебрегая влиянием соседних участков ( $\beta^{*T} \beta \approx N_{\text{и}} E$ )<sup>23</sup>, получаем выражение достаточной статистики:

$$l_m = \sum_{i=1}^I \frac{q_{im}}{1 + q_{im}} \frac{|F_i|^2}{2} - \sum_{i=1}^I \ln(1 + q_{im}), \quad (3.3.14)$$

где  $q_m (i = 1, \dots, I; m = 1, \dots, M)$  — отношение сигнал/шум в  $i$ -м элементе разрешения после когерентного накопления  $N_{\text{и}}$  отсчетов;  $M$  — число классов.

<sup>23</sup> Принятое условие означает, что мы учитываем только тот участок ПРЦ, который попадает в элемент разрешения РСА по азимуту.



При известных априори «радиолокационных портретах» (векторах  $q_{im}$ ) для каждого из классифицируемых типов поверхностей оптимальный алгоритм классификации состоит в том, чтобы вычислить достаточную статистику для каждого возможного  $m$  и выбрать максимальное значение.

$$\hat{m} = \arg \max_m \left\{ - \sum_{i=1}^I \left[ \frac{1}{1 + q_{im}} \frac{|F_i|^2}{2} - \ln(1 + q_{im}) \right] \right\}. \quad (3.3.15)$$

Следует отметить, что радиолокационные портреты» (РП) для различающихся условий наблюдения, как правило, не известны практически ни для одной ПРЦ, что приводит к необходимости их оценки на этапе предварительного обучения. Соответственно алгоритм классификации имеет вид:

$$\hat{m} = \arg \min_m \left\{ \sum_{i=1}^I \frac{1}{1 + \hat{q}_{im}} \frac{|F_i|^2}{2} - \hat{C}_m \right\}. \quad (3.3.16)$$

где знак  $\wedge$  обозначает оценку соответствующего параметра на этапе предварительного обучения.

Следует обратить особое внимание на тот факт, что достоверная оценка РП представляет собой очень сложную в организационном и вычислительном плане задачу, в первую очередь, из-за чрезвычайно большого объема факторов, влияющих на вид радиолокационного портрета. К таким факторам можно отнести зависимость РП от условий наблюдения (дальность, ракурс, длина волны, поляризация), погодных и климатических условий, времени суток и времени года, индивидуальных особенностей, конфигурации и электродинамических свойств наблюдаемых объектов. В то же время, очевидно, что в любом случае основой решения задачи классификации является вектор достаточных статистик

$$\bar{l} = \|l_m\| = \left\| \sum_{i=1}^I \frac{|F_i|^2}{1 + \hat{q}_{im}} \right\|. \quad (3.3.17)$$

Этот вектор является оптимальным вектором признаков для формирования решающего пространства и принятия решения, так как константы  $\hat{C}_m$  не зависят от наблюдаемых данных. Использование этого вектора представляет основу для классификации. Его следует применять на практике во все более возрастающей степени по мере создания банка радиолокационных портретов, полученных в разных условиях наблюдения.

Поскольку на этапе эскизного проектирования говорить о наличии представительного банка РП безусловно преждевременно, для синтеза алгоритма классификации приходится использовать те исходные данные о различии объектов, которые не вызывают сомнений и имеют ясное физическое обоснование. Такими робастными признаками являются размеры и общая ЭПР ПРЦ, в то время как индивидуальные (присущие конкретному участку поверхности) признаки, содержащиеся в РП цели, на этом этапе априори не известны. В тех случаях, когда какие-либо надежные сведения о распределении ЭПР по поверхности цели отсутствуют, целесообразно считать такое распределение равномерным с тем, чтобы ориентироваться на худшую ситуацию, ибо наличие индивидуальных особенностей, отличающих один класс от другого, не может, по крайней мере, потенциально ухудшить эффективность распознавания.

В этом случае при формировании весовых коэффициентов, зависящих от  $\hat{q}_{im}$ , не используется информация о «тонкой» структуре РП, но учитываются априорные сведения об отличии классов объектов по размерам и ориентации областей, занимаемых «портретами» РПЦ на РЛИ. Названные области, в свою очередь, существенно зависят от условий наблюдения, в частности, оценок наклонной дальности и ракурса (при наличии).

В этом случае компоненты вектора  $\bar{l}$  вычисляются путем суммирования отсчетов РЛИ в пределах области, зависящей от номера конкурирующей гипотезы:

$$l_m = \sum_{\Omega_m(\varphi)} |F_i|^2. \quad (3.3.18)$$

Более подробно алгоритм выглядит следующим образом.

По наблюдаемому РЛИ, предъявленному к классификации, прежде всего, производятся две операции:

оценка области, занятой элементами ПРЦ на изображении, например, путем сравнения отсчетов с порогом, установленным по уровню шума;

оценка ракурса  $\hat{\phi}$ , использующая только те отсчеты РЛИ, которые отнесены к цели по результатам предыдущей пороговой обработки.

Поскольку размерность вектора равна числу конкурирующих гипотез, при обучении необходимо моделировать  $T$  выборочных векторов  $l_t$  ( $t = \bar{1}, \bar{T}$ ) при задании объектов каждого из  $M$  классов, расположенных под ракурсом, величина которого оценивается по наблюдаемому РЛИ

$$l_t^{m_0} = \|l_{tk}^{m_0}\| = \left\| \sum_{\Omega_m(\varphi)} |F_i|_{lm_0}^2 \right\|, \quad (3.3.19)$$

где  $|F_i|_{lm_0}^2$  —  $i$ -й отсчет  $t$ -й обучающей выборки при условии, что объект относится к классу  $m_0$ . Следует обратить внимание на отличие индексов  $m$  и  $m_0$ . Первый из них — координата вектора, а второй — номер объекта, для которой производится моделирование выборочных отсчетов РЛИ  $|F_i|_{lm_0}^2$  на этом этапе обучения.

В результате обучения формируются оценки векторов выборочных средних:

$$l^{m_0} = \|l_k^{m_0}\| = \left\| \frac{1}{T} \sum_{t=1}^T l_{tm}^{m_0} \right\| \quad (3.3.20)$$

и выборочных дисперсий:

$$(\sigma^{m_0})^2 = \|(\sigma_m^{m_0})^2\| = \left\| \frac{1}{T} \sum_{t=1}^T (l_{tm}^{m_0} - l_m^{m_0})^2 \right\|. \quad (3.3.21)$$

Принятие решения производится по минимуму расстояния:

$$\hat{m}_0 = \arg \min_{m_0} \sqrt{\sum_{m=1}^M \frac{(l_m - l_m^{m_0})^2}{(\sigma_m^{m_0})^2}}. \quad (3.3.22)$$

Для иллюстрации работы предлагаемого алгоритма рассмотрим решение задачи классификации трёх объектов, отличающихся своими размерами  $\Omega_1, \Omega_2, \Omega_3$ .

Пусть наблюдаемая цель расположена в одном канале дальности, имеет одинаковую удельную ЭПР и отличается от других своими размерами, другими словами,

количеством элементов разрешения, занятых РЛИ цели. Малая цель занимает  $N_M$  элементов, средняя —  $N_C$  и большая —  $N_B$ . Начало цели совместим с началом координат. На рис. 3.5 приведены зависимости удельной ЭПР  $\sigma(i)$  от координат  $i$ .

Рассмотрим функционирование оптимального алгоритма вычисления признаков. Он вычисляет три числа  $\lambda_M, \lambda_C, \lambda_B$ , где

$$\lambda_M = \sum_{i=1}^{N_M} |F_i^2|; \quad \lambda_C = \sum_{i=1}^{N_C} |F_i^2|; \quad \lambda_B = \sum_{i=1}^{N_B} |F_i^2|.$$

При наблюдении «малой» цели все три числа имеют близкие значения (вторая и третья суммы отличаются от первой только суммированием шумовых отсчётов; при отсутствии шума (как на рис. 3.5) дополнительные числа просто равны нулю). При наблюдении «средней» цели первая сумма существенно не изменяется (суммируются те же числа, а вот вторая и третья заметно возрастают за счёт добавления сигнальных отсчётов. В случае наблюдения «большой» цели первая и вторая суммы существенно не изменяются, что и при наблюдении «средней» цели, а третья сумма возрастает (добавление сигнальных отсчётов). Указанные соображения иллюстрируются на рис. 3.5.




Рис. 3.5. Отсчёты РЛИ (случайные числа, распределённые по экспоненциальному закону)

При достаточном отличии в размерах целей в признаковом пространстве образуются три сгруппированные области, характерных для наблюдения каждой из трёх целей (рис. 3.6). Далее решение принимается по одному из известных методов (минимум среднеквадратичного расстояния до центра, метод К ближайших соседей и т. п.).

Моделируя отдельные отсчёты в виде случайных чисел с экспоненциальным распределением (такое распределение имеют отсчёты мощности при исходном нормальном распределении на входе приёмника) и варьируя различие в размерах (средняя от малой, большая от средней отличаются по размерам на  $\delta\%$ ), получаем зависимость вероятности ошибки от различия в размерах (рис. 3.7). Число отсчётов, приходящихся на «малую» цель, фиксировано и равно 5.




Рис. 3.6. Группировка признаков ПРЦ трёх классов




Рис. 3.7. Вероятность правильной классификации в зависимости от различия в размерах ПРЦ

Рассмотренная методология построения алгоритма классификации ПРЦ, опирающаяся на понятие достаточной статистики, поскольку вектор достаточных статистик является оптимальным набором признаков, позволяет решить задачу классификации наилучшим образом в рамках критерия минимума среднего риска. В то же время формирование названного вектора наталкивается на практически непреодолимые трудности из-за очень большой априорной неопределённости. В связи с этим целесообразно искать признаки классификации, начиная с вектора достаточных статистик, при его последовательном упрощении путём отказа от тех деталей и тонких особенностей, которые недоступны классификатору в условиях реальной работы.

По данным РЛС методом искусственного синтеза апертуры формируется радиолокационное изображение наблюдаемой цели. Полученный вектор отсчётов РЛИ умножается на  $M$  векторов, каждый из которых соответствует одному из возможных ожидаемых классов ПРЦ. В результате формируется вектор, размерность которого совпадает с числом классов и вслед за этим определяется  $M$  расстояний между



полученным вектором (вектором признаков) и  $M$  областями, полученными на этапе обучения. Каждая такая область сформирована вектором признаков, соответствующих каждому из  $M$  возможных классов ПРЦ.

Если различаемые гипотезы представляют собой РЛИ однородных поверхностей с различными отражающими свойствами (различными для отличающихся классов, но одинаковыми в пределах синтезированного участка наблюдения ЭПР), то есть  $\sigma_m^2(x_i) = \sigma_m^2$  для всех  $i = \overline{1, I}$ , причём, число классов  $M$  считается известным, а значения  $\sigma_m^2$  неизвестны, применяется непараметрическое правило классификации, заключающееся в сравнении оценки плотности вероятности (гистограммы) случайной величины  $I = \sum |F_i|^2$  с полученными на этапе обучения  $m$  оценками плотностей вероятности соответствующих случайных величин (сумм квадратов амплитуды) для каждого из возможных  $M$  классов поверхностей, расположенных на траектории прогнозируемого полёта ЛА.

### 3.4. Алгоритмы автоматического группирования данных

#### 3.4.1. Чёткая и нечёткая декомпозиции

Достаточно вернуться к анализу результатов предыдущего раздела (рис. 3.6 и комментарии к нему), чтобы убедиться в том, что в основе принятия решения в пространстве оптимальных или близких к оптимальным признаков лежит группирование данных, цель которого заключается в декомпозиции множества признаков на группы однотипных (принадлежащих к одному классу) элементов.

При выборе алгоритма группирования (декомпозиции) следует руководствоваться двумя принципами: гомогенность в группах — в пределах одной группы данные (признаки) должны быть как можно более похожи друг на друга и гетерогенность между группами — данные, принадлежащие различным группам, должны максимально отличаться друг от друга.

Наиболее подходящей мерой подобия данных следует считать расстояние между признаками, например, меру Евклида и т.п. В то же время следует иметь в виду, что при использовании различных мер подобия можно получить группы различной структуры. Пример группирования данных в двумерном пространстве приведён на рис. 3.8.




Рис. 3.8. Группировка данных

Перед нами стоит задача декомпозировать данные, представленные  $n$ -мерными векторами  $x_k = \{x_{k1}, \dots, x_{kn}\}$ , где  $k = 1, 2, \dots, M$  – номер класса ПРЦ. Проводя аналогию с предыдущей задачей,  $M = 3$  – число классов распознаваемых ПРЦ, а  $n$  – число обучающих выборок, каждая из которых формирует вектор признаков (достаточных статистик). Множество  $M$  векторов образует матрицу  $n \times M$

$$\mathbf{X} = \begin{pmatrix} x_{11} & \cdots & x_{M1} \\ \vdots & \ddots & \vdots \\ x_{1n} & \cdots & x_{Mn} \end{pmatrix}. \quad (3.4.1).$$

Столбцы представляют собой объекты, другими словами, пространственно-распределённые цели – ПРЦ, а строки – коэффициенты отношения правдоподобия.

Следует подчеркнуть, что все возможные декомпозиции  $M$  объектов на  $L$  групп представляют собой достаточно большое число, равное

$$\frac{1}{L!} \sum_{i=1}^L \binom{L}{i} (-1)^{(L-i)} i^M. \quad (3.4.2)$$

При  $M = 100$  и  $L = 5$  количество возможных декомпозиций (3.4.2) равно очень большому числу  $6,57 \times 10^{67}$ . Поэтому решающую роль играет метод оптимальной декомпозиции, не требующий перебора всех возможных результатов группирования.

В задачах группирования данных различают три типа декомпозиции: чёткие, нечёткие и возможные, причём последние являются модификацией нечётких [8].

При чётком группировании объект точно принадлежит или не принадлежит к конкретной группе. Цель группирования заключается в декомпозиции данных на  $L$  групп так, чтобы все векторы были распределены по группам, группы не пересекались и ни одна из групп не была пустой, и ни одна группа не содержала всего множества данных. Рассмотрим данные на рис. 3.9.




Рис. 3.9. Пример данных

Чёткая декомпозиция этих данных ( $M = 10$ ) на 3 группы ( $L = 3$ ) может быть представлена следующей матрицей  $U$ :

$$U = \begin{bmatrix} 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 0 \end{bmatrix}. \quad (3.4.3)$$

Отметим, что ПРЦ  $x_{10}$  отнесена ко второй группе, хотя, если судить по рисунку, она должна образовывать новый класс. Но по условию задачи классов должно быть три и объектов, не отнесённых к одному из этих трёх классов, быть не должно.

Это тот случай, когда требуется расширение чёткой композиции, так как в реальных задачах мы не всегда можем отнести ПРЦ к единственной категории. Например, границы между РЛИ малых, средних и больших кораблей точно определить невозможно. В таких случаях существуют два вида декомпозиции: нечёткая и возможная [8]. В этих двух случаях ПРЦ могут входить в произвольное число групп со степенью принадлежности, измеряемой числом из интервала  $[0, 1]$ . При этом выдвигается дополнительное ограничение: сумма членов каждого столбца матрицы  $U$  должна равняться 1. Поэтому такую декомпозицию часто называют вероятностной. В этом случае матрица (3.4.3) может выглядеть следующим образом:

$$U = \begin{bmatrix} 1 & 0,89 & 0,93 & 0,01 & 0,01 & 0,00 & 0,01 & 0,01 & 0,00 & 0,33 \\ 0 & 0,06 & 0,02 & 0,98 & 0,98 & 0,99 & 0,01 & 0,01 & 0,00 & 0,29 \\ 0 & 0,05 & 0,05 & 0,01 & 0,01 & 0,01 & 0,98 & 0,98 & 1 & 0,38 \end{bmatrix}. \quad (3.4.4)$$

Пример матрицы (3.4.4) позволяет интерпретировать ПРЦ  $x_{10}$  как объект с примерно одинаковыми степенями принадлежности ко всем трём группам. Интуитивно мы приписали бы этому объекту малые веса принадлежности к любой из трёх групп, относя его к шуму. Однако, при этом не выполняется условие нормировки. В этих случаях используется, так называемая, возможная декомпозиция, представленная следующей матрицей:

$$U = \begin{bmatrix} 0,87 & 0,44 & 0,79 & 0,04 & 0,03 & 0,03 & 0,05 & 0,04 & 0,05 & 0,12 \\ 0,01 & 0,02 & 0,01 & 0,52 & 0,39 & 0,87 & 0,01 & 0,01 & 0,01 & 0,03 \\ 0,01 & 0,01 & 0,02 & 0,01 & 0,01 & 0,01 & 0,53 & 0,63 & 0,79 & 0,03 \end{bmatrix}. \quad (3.4.5)$$

В этом случае ПРЦ  $x_{10}$  входит во все группы, но с малой степенью принадлежности.

Основным фактором, определяющим декомпозицию данных, является способ определения расстояния между признаками. Наиболее распространённой мерой удалённости служит мера Евклида  $D_{id}$ , интерпретируемая как геометрическое расстояние между двумя точками  $x_d = [x_{d1}, \dots, x_{dn}]$  и  $y_i = [y_{i1}, \dots, y_{in}]$ :

$$D_{id} = \sqrt{\sum_{j=1}^n (x_{dj} - y_{ij})^2} = \|x_d - y_i\|. \quad (3.4.6)$$

Обобщением меры Евклида является метрика Минковского:

$$D_{id} = \left( \sum_{j=1}^n |x_{dj} - y_{ij}|^r \right)^{\frac{1}{r}}. \quad (3.4.7)$$

При  $r = 1$  из меры Минковского следует мера Манхеттен, которая может интерпретироваться как расстояние, полученное перемещением под прямыми углами. Для иллюстрации мер Евклида и Манхеттен на рис. 3.10 показаны названные расстояния между двумя точками  $x_1$  и  $x_2$ .




Рис. 3.10. Расстояния Евклида и Манхеттен

При использовании двоичных переменных мера Манхеттен превращается в меру Хемминга, которая указывает количество битов, отличающих координаты двух точек.

### 3.4.2. Алгоритмы декомпозиции.

Алгоритм НСМ (Hard C-Means) однозначно декомпозирует данные на  $L$  групп. В процессе выполнения алгоритма рассчитываются удалённости каждого вектора  $x_k$ ,  $k = 1, \dots, M$ , от центров групп  $v_i$ ,  $i = 1, \dots, L$ . Принадлежность к группе описывается с помощью матрицы  $U$ , элементы которой равны 1, если элемент принадлежит к группе или 0, если не принадлежит. Алгоритм содержит следующие этапы:

1. Выбор числа групп  $L$  и указание положений их центров.
2. Определение принадлежности элемента к группе по удалённости от выбранного центра.
3. Определение новых центров.
4. Проверка условия завершения выполнения. При невыполнении условия возвращение к этапу 2.

Условием завершения может служить малое изменение значений матрицы  $U$ , а именно,  $U^{(t+1)} - U^{(t)} < \varepsilon$ , где  $\varepsilon$  — априори заданная константа. Блок-схема алгоритма приведена на рис. 3.11.

Алгоритм FCM (Fuzzy C-Means) даёт возможность образовать группы из элементов с разными степенями принадлежности, при этом один и тот же элемент может входить в несколько групп с разными весами соответствия названным группам. Этот



алгоритм предназначен для нечёткого группирования данных. Идея алгоритма заключается в минимизации критерия

$$J(X; U; V) = \sum_{i=1}^L \sum_{k=1}^M (\mu_{ik})^m x_k - v_i^2, \quad (3.4.8)$$

причём  $U = [\mu_{ik}]$  – матрица декомпозиции, элементы которой – суть степень принадлежности признака той или иной группе;

$V = [v_1, v_2, \dots, v_L]$  – матрица центров кластеров, которые должны быть определены в итоге работы алгоритма;

$M$  – коэффициент, характеризующий степень нечёткости групп данных. На практике выбирают  $m = 2$ .

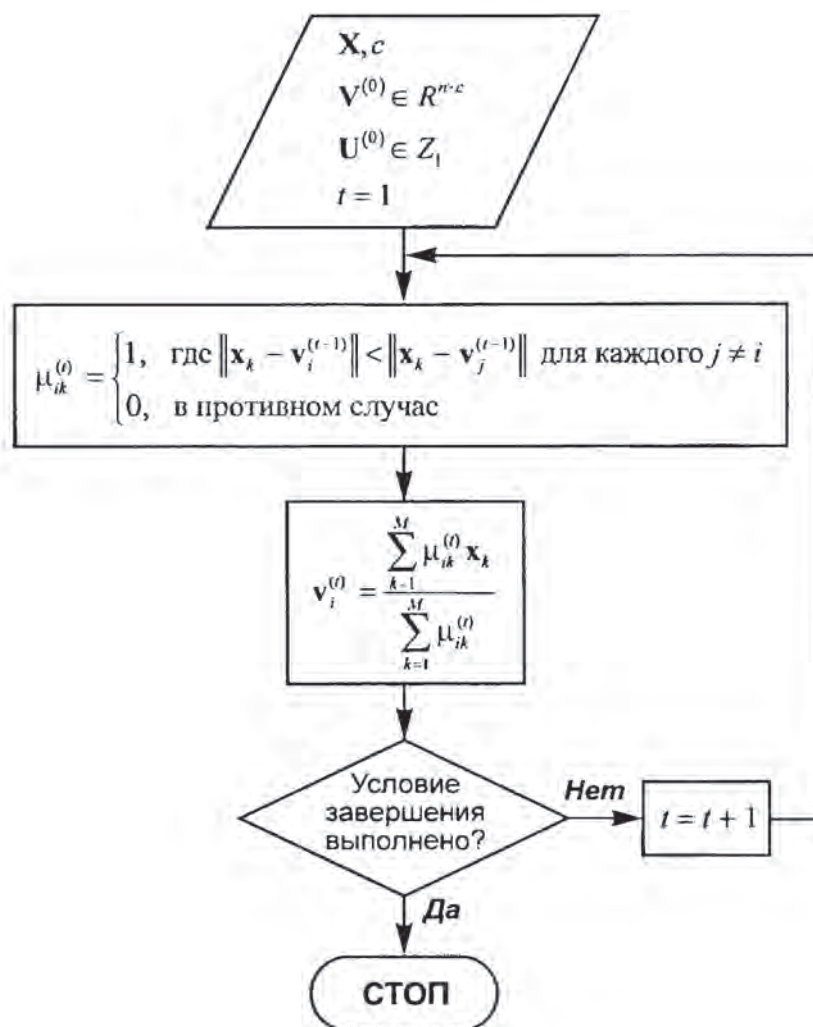


Рис. 3.11. Алгоритм HCM

Для выполнения алгоритма необходимо выбрать количество групп  $L$ , степень нечёткости  $m$ , параметр остановки –  $\varepsilon$ , а также случайным образом инициализировать матрицу  $U^{(0)}$  и вектор прототипов групп  $V^{(0)}$ . Блок схема выполнения алгоритма представлена на рис. 3.12.

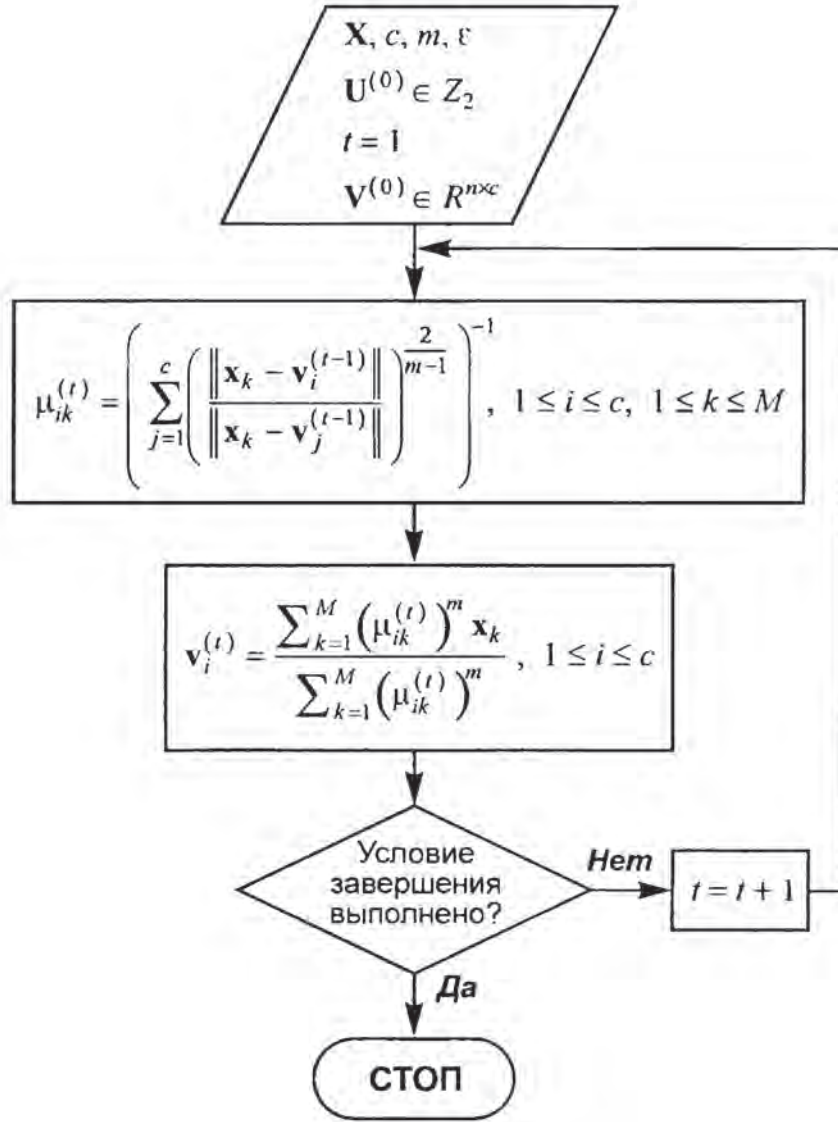


Рис. 3.12. Алгоритм FCM

При отказе от выполнения условия нормировки столбцов матрицы  $\mathbf{U}$  (сумма степеней принадлежности обязательно равна 1) может быть использован алгоритм PCM (Possibilistic C-Means), который минимизирует целевую функцию

$$J(\mathbf{X}; \mathbf{U}; \mathbf{V}) = \sum_{i=1}^L \sum_{k=1}^M (\mu_{ik})^m x_k - v_i^2 + \sum_{i=1}^L \eta_i \sum_{k=1}^M (1 - \mu_{ik})^m, \quad (3.4.9)$$

где  $\eta_i$  — положительная константа.

Блок схема алгоритма показана на рис. 3.13.

Проведём сравнительный анализ алгоритмов HCM, PCM и FCM. На рис. 3.14 представлено множество данных, состоящее из девяти двухмерных объектов ( $M = 9$  и  $n = 2$ ). Соответствующая этому множеству матрица  $\mathbf{X}$  имеет вид:

$$\mathbf{X} = \begin{bmatrix} 98 & 97 & 111 & 109 & 178 & 178 & 190 & 189 & 143 \\ 86 & 99 & 99 & 85 & 85 & 95 & 97 & 85 & 46 \end{bmatrix}.$$

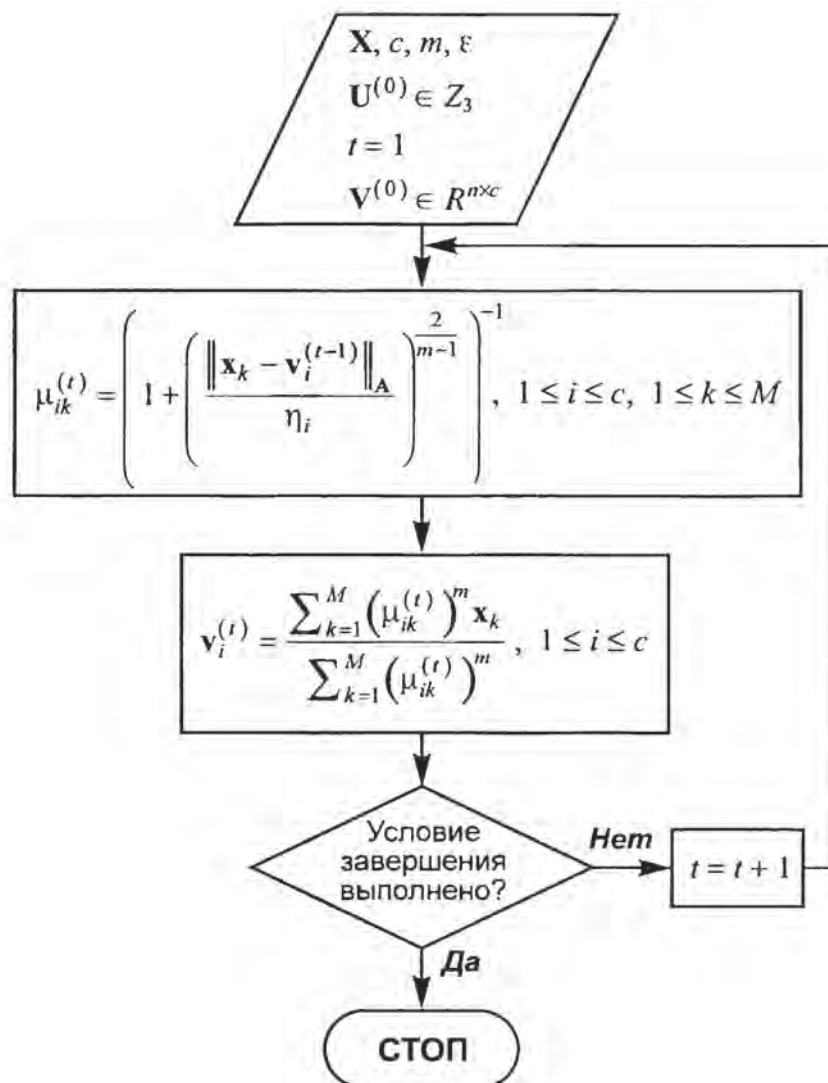


Рис. 3.13. Алгоритм РСМ

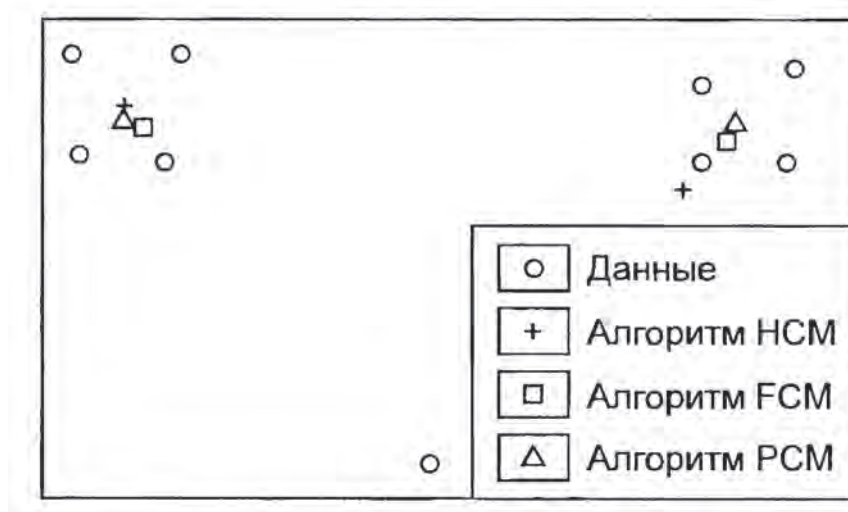


Рис. 3.14. Пример группировки

Нетрудно заметить две группы объектов и индивидуально расположенный объект № 9, не подходящий ни к одной группе. Символом «+» обозначены центры групп, найденные алгоритмом НСМ. Объект № 9 отнесён ко второй группе, и центр группы сместился к объекту № 9. В результате сформирована матрица декомпозиции

$$U_{НСМ} = \begin{bmatrix} 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}. \quad (3.4.10)$$

Алгоритм FCM приписал объект № 9 к обеим группам с одинаковой степенью принадлежности, равной 0,5. В этом случае центры обеих групп смещены к объекту № 9. В результате группирования названным алгоритмом сформирована матрица декомпозиции

$$U_{FCM} = \begin{bmatrix} 0,99 & 0,98 & 0,98 & 0,99 & 0,00 & 0,01 & 0,02 & 0,01 & 0,50 \\ 0,01 & 0,02 & 0,02 & 0,01 & 1,00 & 0,99 & 0,98 & 0,99 & 0,50 \end{bmatrix}. \quad (3.4.11)$$

Лучше всего с проблемой шума справился алгоритм РСМ который «оценил» принадлежность объекта № 9 к первой и второй группам со степенью принадлежности 0,04 и 0,03. В результате была сформирована матрица декомпозиции

$$U_{PCM} = \begin{bmatrix} 0,76 & 0,56 & 0,53 & 0,73 & 0,03 & 0,03 & 0,02 & 0,02 & 0,04 \\ 0,02 & 0,02 & 0,02 & 0,02 & 0,74 & 0,73 & 0,54 & 0,65 & 0,03 \end{bmatrix}. \quad (3.4.12)$$

Центры групп сместились незначительно. Отсюда следует вывод о целесообразности использования алгоритма РСМ в случае сравнительно более интенсивного шума.

### 3.5. Литература к главе 3

1. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА, формируемых в РСА монография — М.: Издательский дом Академии Естествознания, 2017. — 212 с.
2. Радиолокационные станции обзора Земли / под ред. Г.С. Кондратенкова. М.: Радио и связь, 1983. 271 с.
3. Доросинский Л.Г. Классификация радиолокационных изображений / Л.Г.Доросинский // Межд. конф. Теория и техника передачи, приема и обработки информации. /ХТУРЭ. Туапсе 1995. с. 104.
4. Радиолокационные станции с цифровым синтезированием апертуры антенны / под ред. В.Т.Горяинова. М.: Радио и связь, 1988. 304 с.
5. Ван Трис Г. Теория обнаружения, оценок и модуляции: в 3т. / Г. Ван Трис. М.: Сов. радио, 1972. т.1. 744 с.
6. Растрингин Л.А. Метод коллективного распознавания / Л.А. Растрингин, Р.Х. Эринштейн. М.: Энергоиздат, 1981. 80 с.
7. Дуда Р. Распознавание образов и анализ сцен / Р. Дуда, П. Харт; пер с англ. В.Л. Стефанюка. М.: Мир, 1976. 511 с.
8. Рутковский Л. Методы и технологии искусственного интеллекта/пер. с польского И.Д. Рудинского. — М.: Горячая линия — Телеком. 2010. — 520 с.



---

## 4. АНАЛИЗ АЛГОРИТМОВ КЛАССИФИКАЦИИ ПРОСТРАНСТВЕННО-РАСПРЕДЕЛЁННЫХ ЦЕЛЕЙ ПО ДАННЫМ РСА

В данной главе предлагаются методы определения эффективности алгоритмов классификации ПРЦ, основанные на определении вероятностей правильного и ошибочного распознавания классов ПРЦ с помощью аналитических выражений и/или статистического моделирования. Проблема анализа эффективности классификации включает решение трех основных задач, а именно [7, 8]:

1. Разработка методики расчета потенциальной точности классификации (разделы 4.1 и 4.2).
2. Разработка методики расчета вероятностей ошибочных и правильных решений по РЛИ ПРЦ (4.3 и 4.4).
3. Статистическое моделирование (4.5 и 4.6).

### 4.1. Границы Чернова и Кайлата – метод определения потенциальных возможностей классификации ПРЦ по вектору наблюдаемых данных

Потенциальные возможности решения задачи классификации будем оценивать вероятностями правильных ( $P_{\text{пр}}$ ) и ошибочных ( $P_{\text{ош}}$ ) решений, для которых получим граничные соотношения (истинные значения лежат в пределах указанных границ) с помощью известных для различения двух гипотез граничных соотношений Чернова и Кайлата [1, 2, 7].

При проверке ( $M + 1$ ) гипотез о классе наблюдаемой ПРЦ вероятность вынесения ошибочного решения равна:

$$P_{\text{ош}} = \sum_{i=1}^{M+1} p_i \sum_{\substack{j=1 \\ j \neq i}}^{M+1} p(j/i), \quad (4.1.1)$$

где  $p_i$  – априорная вероятность  $i$ -й гипотезы;  $p(j/i)$  – вероятность принятия решения о справедливости  $j$ -й гипотезы в том случае, когда истинной является  $i$ -я гипотеза.

Из (4.1.1) следует:

$$P_{\text{ош}} = \sum_{i=1}^M \sum_{j=i+1}^{M+1} [p_i p(j/i) + p_j p(i/j)]. \quad (4.1.2)$$

При этом верхняя граница ошибки (4.1.2) при проверке многих гипотез может быть получена с использованием методики [1]:

$$P_{\text{ош}} \leq \sum_{i=1}^M \sum_{j=i+1}^{M+1} [p_i Ch_{ij}^F + p_j Ch_{ij}^M], \quad (4.1.3)$$

где  $Ch_{ij}^F$  и  $Ch_{ij}^M$  – границы Чернова для вероятностей ложной тревоги и пропуска цели при проверке пары гипотез  $i$  и  $j$  независимо от остальных гипотез.

Далее получим выражение для нижней границы, вероятностей ошибок, известную для двух гипотез, как граница Кайлата [3].

Ошибка возникает, если хотя бы для одной из альтернативных гипотез выполняется неравенство:

$$l_{ij} > l_{ii} \quad (i \neq j), \quad (4.1.4)$$

в котором

$$l_{ij} = \ln \left( \frac{W_j(U)}{W_i(U)} \right) \quad (4.1.5)$$

– логарифм отношения правдоподобия при проверке пары гипотез с номерами  $j$  и  $i$ ;  $W_j(U)$  и  $W_i(U)$  – плотности распределения вероятностей значений вектора наблюдаемых данных  $U$  по гипотезам  $j$  и  $i$ . Пусть событие  $A_j$  соответствует выполнению условия (4.1.4). Тогда вероятность ошибки при наблюдении  $i$ -го класса целей представляется как вероятность суммы событий:

$$\sum_{\substack{j=1 \\ j \neq i}}^{M+1} P(j/i) = P \left[ \sum_{\substack{j=1 \\ j \neq i}}^{M+1} A_j \right]. \quad (4.1.6)$$

Используя формулу для определения вероятности суммы зависимых событий [4], можно убедиться в справедливости неравенства:

$$P \left[ \sum_{\substack{j=1 \\ j \neq i}}^{M+1} A_j \right] \geq \max_{\substack{j \\ j \neq i}} P[A_j]. \quad (4.1.7)$$

В этом выражении  $P[A_j]$  представляет собой вероятность вынесения решения в пользу  $j$ -го класса целей при условии, что истинной является цель  $i$ -го класса при проверке только этой пары альтернатив. Обозначая эту вероятность  $P_2(j/i)$  и используя (4.1.7), для вероятности ошибки (4.1.1) запишем неравенство:

$$P_{\text{ош}} \geq \sum_{i=1}^{M+1} P_i P_2(j/i), \quad (4.1.8)$$

где на значение  $j$  наложено единственное ограничение:

$$j \neq i. \quad (4.1.9)$$

Неравенство (4.1.8) позволяет оценить нижнюю границу вероятности ошибки в случае проверки более двух гипотез. Найдём решение для трёх классов

Используя (4.1.8) и (4.1.9), запишем два очевидных неравенства:

$$\begin{aligned} P_{\text{ош}} &\geq P_1 P_2(2/1) + P_2 P_2(3/2) + P_3 P_2(1/3); \\ P_{\text{ош}} &\geq P_1 P_2(3/1) + P_2 P_2(1/2) + P_3 P_2(2/3). \end{aligned} \quad (4.1.10)$$

Суммируя правые и левые части этих неравенств, получим:

$$P_{\text{ош}} \geq 0,5 \sum_{i=1}^{23} \sum_{j=i+1}^{23} [P_i P_2(j/i) + P_j P_2(i/j)]. \quad (4.1.11)$$

Учитывая, что:

$$P_i + P_j \neq 1. \quad (4.1.12)$$

и используя критерий минимума ошибки, для ситуации, изображённой на рис. 4.1, получим:

$$\begin{aligned}\int P_i W_i(U) dU &= P_i = A + C + D, \\ \int P_j W_j(U) dU &= P_j = B + C + D.\end{aligned}\quad (4.1.13)$$




Рис. 4.1. К вопросу о нижней границе вероятности ошибки

Суммируя их, имеем:

$$A + B + 2(C + D) = P_i + P_j. \quad (4.1.14)$$

Нетрудно заметить, что:

$$A + B = \int |P_i W_i(U) - P_j W_j(U)| dU. \quad (4.1.15)$$

Отсюда, искомая вероятность ошибки равна:

$$C + D = 0,5 \left\{ P_i + P_j - \int |P_i W_i(U) - P_j W_j(U)| dU \right\}. \quad (4.1.16)$$

Для оценки интеграла (3.1.15) применим неравенство Шварца [4]:

$$\begin{aligned}\left[ \int |P_i W_i(U) - P_j W_j(U)| dU \right]^2 &\leq \left\{ \int \left| [P_i W_i(U)]^{1/2} - [P_j W_j(U)]^{1/2} \right|^2 dU \right\} \times \\ &\times \left\{ \int \left| [P_i W_i(U)]^{1/2} + [P_j W_j(U)]^{1/2} \right|^2 dU \right\}.\end{aligned}\quad (4.1.17)$$

После преобразования правой части (3.1.17) получим:

$$(A + B)^2 \leq (P_i + P_j)^2 - 4 \left\{ (P_i P_j)^{1/2} \int [W_i(U) W_j(U)]^{1/2} dU \right\}^2. \quad (4.1.18)$$

Следовательно

$$P_i P_2(j/i) + P_j P_2(i/j) = C + D \geq Kl_{ij}, \quad (4.1.19)$$

где

$$Kl_{ij} = 0,5 \left\{ P_i + P_j - \sqrt{(P_i + P_j)^2 - 4 \left[ (P_i P_j)^{1/2} \int [W_i(U) W_j(U)]^{1/2} dU \right]^2} \right\}. \quad (4.1.20)$$

Это выражение можно представить в виде:

$$Kl_{ij} = 0,5 \left\{ P_i + P_j - \sqrt{(P_i + P_j)^2 - 4 \left\{ (P_i P_j)^{1/2} \exp[\mu_{ij}(0,5)] \right\}^2} \right\}, \quad (4.1.21)$$

где

$$\mu_{ij}(s) = \ln \left( \int_{-\infty}^{\infty} [W_j(U)]^s [W_i(U)]^{1-s} dU \right). \quad (4.1.22)$$

Окончательно для (4.1.11) имеем:

$$P_{\text{Ош}} \geq 0,5 \sum_{i=1}^2 \sum_{j=i+1}^3 Kl_{ij}. \quad (4.1.23)$$

При проверке  $M + 1$  гипотез имеем:

$$P_{\text{Ош}} \geq \frac{1}{M} \sum_{i=1}^M \sum_{j=i+1}^{M+1} Kl_{ij}. \quad (4.1.24)$$

Если наблюдаемые данные имеют векторный характер, изменения затрагивают только выражение (4.1.22) для логарифма производящей функции моментов, которое принимает следующий вид:

$$\mu_{ij}(s) = \ln \left( \int_{-\infty}^{\infty} [W_j(U)]^s [W_i(U)]^{1-s} dU \right). \quad (4.1.25)$$

Применяя методику [5] получим: имеем:

$$Ch_{ij}^{F1} = Ch_{ij}^{F1} - Ch_{ij}^{F2} \frac{\gamma_3}{6}; \quad (4.1.26)$$

$$Ch_{ij}^{M1} = Ch_{ij}^{M1} - Ch_{ij}^{M2} \frac{\gamma_3}{6}, \quad (4.1.27)$$

где

$$Ch_{ij}^{F1} = \exp[\mu_{ij}(s) - s\dot{\mu}_{ij}(s)] I_0[s\sqrt{\ddot{\mu}_{ij}(s)}]; \quad (4.1.28)$$

$$Ch_{ij}^{M1} = \exp[\mu_{ij}(s) - (1-s)\dot{\mu}_{ij}(s)] I_0[(1-s)\sqrt{\ddot{\mu}_{ij}(s)}]; \quad (4.1.29)$$

$$Ch_{ij}^{F2} = \exp[\mu_{ij}(s) - s\dot{\mu}_{ij}(s)] \left\{ [s\sqrt{\ddot{\mu}_{ij}(s)}]^3 I_0[s\sqrt{\ddot{\mu}_{ij}(s)}] + \frac{1}{(2\pi)^{1/2}} [1 - s^2 \mu_{ij}(s)] \right\}; \quad (4.1.30)$$

$$Ch_{ij}^{M2} = \exp[\mu_{ij}(s) + (1-s)\dot{\mu}_{ij}(s)] \times \\ \times \left\{ [(1-s)^2 \ddot{\mu}_{ij}(s) - 1] \frac{1}{(2\pi)^{1/2}} - [(1-s)\sqrt{\ddot{\mu}_{ij}(s)}]^3 I_0[(1-s)\sqrt{\ddot{\mu}_{ij}(s)}] \right\}; \quad (4.1.31)$$

$$\gamma_3 = \frac{\mu_{ij}^{(3)}(s)}{[\sqrt{\ddot{\mu}_{ij}(s)}]^3}; \quad (4.1.32)$$

$$I(\alpha) = \exp\left(\frac{\alpha^2}{2}\right) \frac{1}{(2\pi)^{1/2}} \int_{\alpha}^{\infty} \exp\left(-\frac{t^2}{2}\right) dt. \quad (4.1.33)$$



Значение аргумента  $s$  в (4.1.29)–(4.1.32) находится путем решения уравнения

$$\dot{\mu}_{ij}(s) = \ln \frac{P_i}{P_j}. \quad (4.1.34)$$

Если вектор наблюдаемых данных  $U$  представляет собой совокупность комплексных гауссовских отсчетов с нулевыми средними значениями для  $\mu_{ij}(s)$  может быть получено следующее выражение:

$$\mu_{ij}(s) = (s-1) \ln [R_i] + s \ln [R_j] - \ln \left\{ [sR_j^{-1} - (1-s)R_j^{-1}] \right\}. \quad (4.1.35)$$

где  $R_i$  и  $R_j$  – корреляционные матрицы вектора  $Y$  по гипотезам  $i$  и  $j$  соответственно. Разложим эрмитову матрицу  $R_j$  на множители по Холецкому:

$$R_j = L_j L_j^*. \quad (4.1.36)$$

где  $L_j$  – нижняя (левая) треугольная матрица, а символ  $*$  обозначает эрмитово сопряжение.

При этом выражение (3.1.35) может быть представлено в виде:

$$\mu_{ij}(s) = \sum_k \left[ s \ln \lambda_k^{ij} - \ln (s \lambda_k^{ij} + 1 - s) \right], \quad (4.1.37)$$

где  $\lambda_k^{ij}$  –  $k$ -е собственное значение матрицы:

$$K_{ij} = L_j^{-1} R_i (L_j^*)^{-1}. \quad (4.1.38)$$

Искомые производные функции  $\mu_{ij}(s)$  имеют вид:

$$\mu_{ij}(s) = \sum_k \left[ \ln \lambda_k^{ij} - \frac{\lambda_k^{ij} - 1}{s \lambda_k^{ij} + 1 - s} \right]; \quad (4.1.39)$$

$$\dot{\mu}_{ij}(s) = \sum_k \left[ \frac{\lambda_k^{ij} - 1}{s \lambda_k^{ij} + 1 - s} \right]^2; \quad (4.1.40)$$

$$\ddot{\mu}_{ij}(s) = -2 \sum_k \left[ \frac{\lambda_k^{ij} - 1}{s \lambda_k^{ij} + 1 - s} \right]^3. \quad (4.1.41)$$

Таким образом, для определения ошибок необходимо знание корреляционной матрицы отсчетов РЛИ, получаемого в отдельной  $p$ -й РЛС системы при наблюдении  $k$ -й цели.

РЛИ цели можно представить в виде суммы трех составляющих: шумовой

$$F_{pN}(\bar{p}/\bar{x}^0, \bar{x}) = \int E_p^*(\bar{p}, t/\bar{x}^0, \bar{x}) S_p^*(\bar{p}, t/\bar{x}^0, \bar{x}) G_p(\bar{p}, t/\bar{x}^0, \bar{x}) N_p(t) dt, \quad (4.1.42)$$

диффузионной

$$F_{pk}^0(\bar{p}/\bar{x}^0, x) = U_{kp} \int \Phi_p(\bar{p}, \bar{x}) f_{k0}^p(\bar{x}) d\bar{x} \quad (4.1.43)$$

и составляющей, вызванной наличием «блестящих точек» в составе модели ПРЦ  $k$ -го класса:

$$F_{pk}^1(\bar{p}/\bar{x}^0, \bar{x}) = U_{kp} \sum_i \varphi_p(\bar{p}, \bar{p}_{ki}^p) f_{ki}^p. \quad (4.1.44)$$

Эти составляющие независимы между собой, и, следовательно, элементы искомой корреляционной матрицы представимы в виде суммы:

$$R_{pklm} = R_{pNlm} + R_{pklm}^0 + R_{pklm}^1, \quad (4.1.45)$$

$$\text{где} \quad R_{pNlm} = N_{p0} \varphi_p^0(\bar{p}_l, \bar{p}_m); \quad (4.1.46)$$

$$R_{pklm}^0 = U_{kp}^2 \int [\sigma_{ko}^p(\bar{x})]^2 \varphi_p(\bar{p}_l, \bar{x}) \varphi_p^*(\bar{p}_m, \bar{x}) d\bar{x}; \quad (4.1.47)$$

$$R_{pklm}^1 = U^2 \sum \varphi_p(\bar{p}_l, \bar{p}_{ki}^p) \varphi_p(\bar{p}_m, \bar{p}_{ki}^p) [\sigma_{ki}^p]^2. \quad (4.1.48)$$

Дискретные значения  $\bar{p}_l$  и  $\bar{p}_m$  задают координаты отсчетов РЛИ на плоскости изображения.

Вводя нормированные функции неопределенности  $\varphi_{pH}^0$  и  $\varphi_{pH}$  и пренебрегая константами, не влияющими на вычисление функции  $\mu_{ij}(s)$  и ее производных, выражение (4.1.45) можно представить в следующем виде:

$$R_{pklm} = q_{kp} (2N_{\text{ир}} + 1) \int [\sigma_{ko}^p(\bar{x})]^2 \varphi_{pH}(\bar{p}_l, \bar{x}) \varphi_{pH}(\bar{p}_m, \bar{x}) d\bar{x} + \\ + q_{kp} (2N_{\text{ир}} + 1) \sum_i [\sigma_{ki}^p] \varphi_{pH}^2(\bar{p}_l, \bar{p}_{ki}^p) \varphi_{pH}^*(\bar{p}_m, \bar{p}_{ki}^p) + \varphi_{pH}^0(p_l, p_m), \quad (4.1.49)$$

$$\text{где} \quad q_{kp} = \frac{2P_{p0} \lambda_p^2 G_{1p} G_{2p} (\sigma_{ke}^p)^2 \tau_p}{(4\pi)^3 N_{p0} R_{1p}^2 R_{2p}^2}. \quad (4.1.50)$$

представляет собой эквивалентное отношение энергии сигнала к спектральной плотности шума в импульсе для случая наблюдения точечного отражателя с ЭПР, равной суммарной ЭПР цели  $(\sigma_{ke}^p)^2$ , при расположении его в точке, соответствующей центру цели. Выражение

$$q_{ke}^p = q_{kp} (2N_{\text{и}} + 1) \quad (4.1.51)$$

следует рассматривать как суммарное отношение сигнал/шум по пачке из  $(2N_{\text{и}} + 1)$  импульсов.

## 4.2. Анализ потенциальных характеристик классификации ПРЦ по вектору наблюдаемых данных

Примером анализа служит отыскание границ, полученных в предыдущем разделе, в случае наблюдения трёх классов ПРЦ, отличающихся размерами и суммарной ЭПР. Суммарная ЭПР каждой цели считается равномерно распределённой по поверхности ПРЦ, которая представляет собой прямоугольник. В качестве эталонов для каждого класса используются их «средние» представители: цель  $N1$

(«большая цель») размером  $360 \times 30$  м, цель  $N2$  («средняя цель») –  $240 \times 20$  м и цель  $N3$  («малая цель») –  $120 \times 10$  м. Ракурс наблюдения для всех ПРЦ считается одинаковым и равным  $90^\circ$ . Будем считать, мощности сигналов, отраженных от целей разных классов при наблюдении под одинаковыми ракурсами, отличаются ориентировочно на 3 дБ. Предположим, что разрешающая способность РСА по азимуту и дальности одинакова, т. е.

$$Dx = Dy. \quad (4.2.1)$$

При этом условии обеспечивается равенство масштабов формируемого РЛИ.

На рис. 4.2 приведены зависимости верхней

$$P_{\text{пр}} = 1 - 0,5 \sum_{i=1}^2 \sum_{j=i+1}^3 Kl_{ij} \quad (4.2.2)$$

и нижней

$$P_{\text{пр}} = 1 - \sum_{i=1}^2 \sum_{j=i+1}^3 (P_i Ch_{ij}^p + P_j Ch_{ij}^M) \quad (4.2.3)$$

границ вероятности правильного распознавания от суммарного отношения сигнал/шум для цели  $N2$  ( $q_{2\epsilon}$ ) при различных значениях разрешения. Отношения сигнал/шум для двух других целей отличаются на 3 дБ:

$$q_{1\epsilon} = q_{2\epsilon} + 3 \text{ дБ}; \quad q_{3\epsilon} = q_{2\epsilon} - 3 \text{ дБ}. \quad (4.2.4)$$




Рис. 4.2. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от суммарного отношения сигнал/шум (для цели 2-го класса; цели 1-го и 3-го классов отличаются на  $\pm 3$  дБ)

Анализ влияния разрешения на качество распознавания демонстрирует рис. 4.3.




Рис. 4.3. Верхние (V) и нижние (H) границы вероятностей правильной классификации в зависимости от разрешающей способности (при фиксированном суммарном отношении сигнал/шум)

В случае фиксированного отношения сигнал/шум в каждом импульсе (без ограничений общей энергетики пачки) вероятность правильной классификации так же существенно зависит от разрешающей способности (рис. 4.4.)




Рис. 4.4. Верхние (V) и нижние (H) границы вероятностей правильной классификации в зависимости от разрешающей способности (при фиксированном отношении сигнал/шум в импульсе)



Влияние различий в ЭПР и размерах ПРЦ на эффективность их классификации иллюстрируется на рис. 4.5–4.9. На рис. 4.6 и 4.7 приведены зависимости вероятности правильного распознавания от разницы в линейных размерах ПРЦ, выраженной в долях по отношению к размеру цели 2-го класса ( $\Delta$ ) при разрешении 30 и 10 м. Размеры ( $L$  – длина,  $S$  – ширина) целей определяются равенствами:




Рис. 4.5. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от разрешающей способности (при фиксированном суммарном отношении сигнал/шум)




Рис. 4.6. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от различий в размерах целей (при фиксированном значении суммарного отношения сигнал/шум)




Рис. 4.7. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от различий в размерах целей (при фиксированном значении суммарного отношения сигнал/шум)




Рис. 4.8. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от различий в суммарной ЭПР целей (при фиксированных значениях суммарного отношения сигнал/шум; цели не отличаются размерами)




Рис. 4.9. Верхние (В) и нижние (Н) границы вероятностей правильной классификации в зависимости от различий в суммарной ЭПР целей (при фиксированных значениях суммарного отношения сигнал/шум; цели отличаются размерами)

### 4.3. Методика расчета эффективности классификации ПРЦ по радиолокационному портрету

#### 4.3.1. Проблема анализа эффективности алгоритмов классификации

В качестве основного метода классификации, разумно сочетающего близость к оптимальному с относительно простой технической реализацией, может быть использован следующий алгоритм, предложенный в главе 2. В качестве решения принимается гипотеза о классе с номером  $\hat{k}$ , для которого выполняется соотношение:

$$\hat{k} = \underset{k}{\operatorname{argmin}} l(k) = \underset{k}{\operatorname{argmin}} \left\{ \sum_{i \in \Omega_k} \left[ \frac{\eta_i}{\xi_i^k} + \ln \xi_i^k \right] \right\}, \quad (4.3.1)$$

где  $\eta_i = |F_i|^2$  –  $i$ -й отсчет РЛИ наблюдаемого ПРЦ;  $\xi_i^k = 1 + \hat{q}_i$  –  $i$ -й отсчет ожидаемого значения ЭПР (радиолокационного портрета) цели  $k$ -го класса.

Вероятность принятия решения о справедливости  $k$ -й гипотезы при условии, что истинна 1-я, определяется выражением:

$$P(k/l) = \int_G \sigma(\gamma_k / \bar{\eta}) P(\bar{\eta}/l) d\bar{\eta}, \quad (4.3.2)$$

где  $G$  – пространство решений;  $\sigma(\gamma_k / \bar{\eta})$  – правило решения;  $\bar{\eta}$  – вектор принимаемых данных;  $P(\bar{\eta}/l)$  – плотность распределения принимаемых данных при условии, что истинна гипотеза «1».

Производя замену переменных и выбирая в качестве новой переменной функцию

$$y_k = l(k), \quad (4.3.3)$$

приходим к выражению для вероятности ошибки в виде многомерного интеграла от совместного распределения статистик  $y_1 \dots y_N$  по той области пространства решений, которая соответствует  $k$ -й гипотезе:

$$P(k/l) = \int_{G_k} W^{(l)}(y_1 \dots y_M) dy_1 \dots dy_M, \quad (4.3.4)$$

где  $W^{(l)}(\bar{y})$  – совместная плотность распределения случайных величин  $y_1 \dots y_M$  при условии, что принимается 1-я гипотеза;  $M$  – общее число принимаемых гипотез;  $G_k$  – область пространства решений, соответствующая принятию  $k$ -й гипотезы.

В рассматриваемом случае пределы интегрирования в выражении для вероятности принятия решения о наличии цели  $k$ -го класса при наблюдении цели 1-го класса могут быть конкретизированы:

$$P(k/l) = \int_{-\infty}^{\infty} dy_k \int_{-\infty}^{y_k} \dots \int_{-\infty}^{y_k} W^{(l)}(y_1 \dots y_N) dy_1 \dots dy_N. \quad (4.3.5)$$

Плотность распределения  $W^{(l)}(\bar{y})$  выражается через значения отсчетов РЛИ с помощью формулы:

$$W^{(l)}(\bar{y}) = \int_{\Gamma} P(\bar{\eta}/l) \prod_{\alpha=1}^M \sigma(y_{\alpha} Y(\alpha)) d\bar{\eta}. \quad (4.3.6)$$

С учетом независимости компонент вектора наблюдений  $\bar{\eta}$  плотность вероятности  $P(\bar{\eta}/l)$  имеет вид:

$$P(\bar{\eta}/l) = \prod_{i=1}^N \frac{1}{\xi_i^{(l)}} \exp\left\{-\frac{\eta_i}{\xi_i^{(l)}}\right\}, \quad (4.3.7)$$

где  $N$  – размерность вектора наблюдений  $\bar{\eta}$ .

Определим  $\sigma$  – функцию, входящую в (4.3.5), следующим образом:

$$\delta(y_{\alpha} - Y(\alpha)) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \exp\{-jz_{\alpha} [y_{\alpha} - Y(\alpha)]\} dz_{\alpha}.$$

Подставляя (4.3.2) в (4.3.7) и (4.3.6) в (4.3.5), получим:

$$\begin{aligned} W^{(l)}(\bar{y}) = \int_{\Gamma} & \left\{ \prod_{i=1}^N \frac{1}{\xi_i^{(l)}} e^{\frac{\eta_i}{\xi_i^{(l)}}} \right\} \times \left\{ \frac{1}{(2\pi)^N} \prod_{\alpha=1}^M \int_{-\infty}^{\infty} \exp[-jz_{\alpha} (y_{\alpha} + \right. \\ & \left. + \sum_{i=1}^N \frac{\eta_i}{\xi_i^{(\alpha)}} + \sum_{i=1}^N \ln \xi_i^{(\alpha)}] dz_{\alpha} \right\} d\eta_1 \dots d\eta_N. \end{aligned} \quad (4.3.8)$$

После замены переменных:

$$x_{\alpha} = y_{\alpha} + \sum_{i=1}^N \ln \xi_i^{(\alpha)} \quad (4.3.9)$$



определим характеристическую функцию, соответствующую плотности распределения

$$\begin{aligned} F(z_1, \dots, z_N) &= \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \exp \left[ j \sum_{i=1}^M z_i y_i \right] W^{(l)}(y_1 \dots y_M) dy_1 \dots dy_M = \\ &= \prod_{i=1}^N \frac{1}{1 + j \sum_{\alpha=1}^M \frac{\xi_i^{(l)}}{\xi_i^{(\alpha)}} z_{\alpha}}. \end{aligned} \quad (4.3.10)$$

Для определения плотности вероятности  $W^{(l)}(\bar{x})$  найдем обратное преобразование Фурье от последнего выражения (4.3.10):

$$\begin{aligned} W^{(l)}(\bar{x}) &= \frac{1}{(2\pi)^N} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \exp \left[ -j \sum_{\alpha=1}^M z_{\alpha} x_{\alpha} \right] F(z_1 \dots z_M) dz_1 \dots dz_M = \\ &= \frac{1}{(2\pi)^N} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \left\{ \prod_{i=1}^N \frac{1}{1 + j \sum_{\alpha=1}^M \frac{\xi_i^{(l)}}{\xi_i^{(\alpha)}} z_{\alpha}} \right\} e^{-j \sum_{\alpha=1}^M z_{\alpha} x_{\alpha}} dz_1 \dots dz_M. \end{aligned} \quad (4.3.11)$$

Вычисление полученного интеграла приводит к чрезвычайно громоздким результатам. И тем не менее эти вычисления следовало бы привести при том условии, что полученные выражения носили бы конструктивный характер, а именно позволяли бы рассчитать вероятности ошибочных решений.

Поэтому рассмотрим вначале частный случай, при котором вычисление (4.3.11) тривиально и убедимся в степени продуктивности полученного решения для анализа эффективности распознавания в целом.

Допустим, что размерность вектора наблюдений, равная  $N$ , совпадает с числом конкурирующих гипотез  $M$ . На практике обычно выполняется неравенство  $N > M$ . Тем не менее, такое предположение не лишено целесообразности. Оно приводит к расширению числа классов ПРЦ — появлению подклассов в пределах каждого класса, что делает задачу анализа эффективности классификации более детальной. После расчета вероятностей ошибок, если, разумеется, такой расчет удастся осуществить аналитическими методами, результаты можно «заглубить», объединяя вероятности ошибочных решений внутри подкласса.

После замены переменных:

$$p = \sum_{\alpha=1}^M \frac{\xi_i^{(l)}}{\xi_i^{(\alpha)}} z_{\alpha} \quad (4.3.12)$$

или в матричной записи:

$$\begin{aligned} Q^{(l)} \bar{Z} &= \bar{P}, \\ Q^{(l)} &= q_{ij}^{(l)} = \frac{\xi_i^{(l)}}{\xi_i^{(j)}} \end{aligned} \quad (4.3.13)$$

и предположения о том, что матрица  $Q$  — неособенная, перепишем формулу (3.3.11):

$$\begin{aligned} W^{(l)}(\bar{x}) &= \frac{1}{(2\pi)^N} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \left\{ \prod_{i=1}^N \frac{1}{1 + jp_i} \right\} \frac{1}{|Q^{(l)}|} e^{-j [Q^{(l)-1} \bar{P}]} d\bar{P} = \\ &= \frac{1}{|Q^{(l)}|} \prod_{i=1}^N \int_{-\infty}^{\infty} \frac{1}{2\pi} \frac{1}{1 + jp_i} e^{-jp_i x_i} dp_i. \end{aligned} \quad (4.3.14)$$

В последнем выражении приняты следующие обозначения:

$$\gamma_i = \sum_{l=1}^M x_i c_{il}, \quad (4.3.15)$$

где, в свою очередь,  $c_{il}$  — элемент матрицы:

$$C = (Q^{(l)})^{-1}. \quad (4.3.16)$$

Интегралы, стоящие в (4.3.14), легко вычисляются, и выражение для плотности вероятности принимает вид:

$$W^{(l)}(x) = \begin{cases} \frac{1}{|Q^{(l)}|} e^{\sum_{ij} x_i c_{ij}} & \text{если } \sum_i x_i c_{ji} < 0 \text{ для каждого } j = \overline{1, M}; \\ 0 & \text{если } \sum_i x_i c_{ji} > 0 \text{ для каждого } j = \overline{1, M}. \end{cases} \quad (4.3.17)$$

Подставив (4.3.17) в выражение (4.3.5), получим формулу для расчета вероятностей ошибок:

$$P(k / l) = \int dx \int \dots \int \dots \times \times \frac{1}{|Q^{(l)}|} e^{\sum_{ij} x_i c_{ij}} dx_1 \dots dx_n, \quad (4.3.18)$$

при условии  $\sum_{i=1}^N x_i c_j < 0$  для каждого  $j = \overline{1, M}$ .

Вычисление последнего интеграла аналитическими методами представляет собой непреодолимую задачу. Общий случай ( $M \neq N$ ) еще более сложен.

#### 4.3.2. Вывод расчетных выражений для оценки вероятностей правильных и ошибочных решений при классификации ПРЦ по РЛИ

Рассмотрим приближенный метод [7] определения вероятностей правильных и ошибочных выборов гипотез о классах ПРЦ. Алгоритм проверки гипотез принимает решение об истинности класса ПРЦ, если соответствующее ему значение статистики:

$$l(k) = -\sum_{i=1}^N \left( \frac{\eta_i}{\xi_i^{(k)}} + \ln \xi_i^{(k)} \right), \quad (4.3.19)$$

основанной на модели плотности вероятности наблюдаемого вектора (3.3.7), принимает максимальное значение.

Для выходной статистики, построенной в предположении, что ПРЦ соответствует  $k$ -му классу при условии, что на самом деле вектор наблюдаемых данных  $\bar{\eta}$  соответствует 1-му классу, введем обозначение  $l^{(1)}(k)$ .

Ошибка классификации имеет место в том случае, когда при наблюдении РЛИ ПРЦ 1-го класса выносится решение в пользу ПРЦ  $k$ -го класса. Такая ситуация наступает, если выходной эффект, соответствующий  $k$ -й гипотезе  $l^{(k)}()$ , оказывается больше, чем выходной эффект, соответствующий истинной гипотезе 1:

$$l^{(k)}() > l^{(1)}(). \quad (4.3.20)$$

Вероятность этого события определяется выражением:

$$\begin{aligned} P[l^{(k)}() > l^{(1)}()] &= P[l^{(k)}() - l^{(1)}() > 0] = \\ &= P\left[\sum_{i=1}^m \left(\frac{1}{\xi_i^{(1)}} - \frac{1}{\xi_i^{(k)}}\right) \eta_i > \sum_{i=1}^m \ln \frac{\xi_i^{(k)}}{\xi_i^{(1)}}\right]. \end{aligned} \quad (4.3.21)$$

В общем случае формула для вероятности правильного решения может быть записана следующим образом:

$$P(l/l) = 1 - P\left[l^{(k)}() > l^{(1)}() \text{ для любых } k = \overline{1, m} \atop k \neq 1\right]. \quad (4.3.22)$$

Поскольку выходной эффект  $l^{(k)}()$  может превышать статистику  $l^{(1)}()$  при нескольких значениях  $k$  (события совместны), точный расчет вероятностей в правой части (3.3.22) довольно сложен (формально эта процедура не отличается от описанной в предыдущем параграфе). Однако, используя только вероятности (3.3.21), удастся записать выражение для нижней границы вероятности правильного решения:

$$P(l/l) \geq 1 - \sum_{\substack{k=1 \\ k \neq 1}}^M P[l^{(k)}() > l^{(1)}()]. \quad (4.3.23)$$

Следует иметь в виду, что с повышением точности классификации нижняя граница вероятности правильного решения (4.3.23) приближается к истинному значению вероятности. Действительно, чем выше эффективность устройства классификации, тем меньше вероятность события, заключающегося в том, что выходные эффекты, соответствующие двум и более ложным гипотезам, будут превышать статистику (3.3.19), соответствующую наблюдению истинной цели. Приведенное заключение имеет тем больше оснований, чем меньше число конкурирующих гипотез, что соответствует рассматриваемой ситуации классификации ПРЦ. Введем обозначения:

$$u = \sum_{i=1}^N \left(\frac{1}{\xi_i^{(1)}} - \frac{1}{\xi_i^{(k)}}\right) \eta_i, \quad (4.3.24)$$

$$Q = \sum_{i=1}^N \ln \frac{\xi_i^{(k)}}{\xi_i^{(1)}} \quad (4.3.25)$$

причем  $\xi_i^{(l)} \# \xi_i^{(k)}$  (в противном случае отсчеты конкурирующих РЛИ не отличаются и соответствующие значения ЭПР исключаются из рассмотрения),

$$p_l^k = P[l^{(l)}(k) > l^{(l)}(l)], \quad (4.3.26)$$

где

$$p_l^k = P\left(\frac{k}{l}\right) = \int_0^\infty W\left(\frac{u}{l}\right) du. \quad (4.3.27)$$

В (4.3.27) функция  $W(u/l)$  представляет собой плотность распределения вероятностей случайной величины  $u$ , определенной из (4.3.24), при условии, что случайные величины  $\eta_i$ , как это следует из исходной постановки задачи, имеют плотность распределения вероятностей:

$$W(\eta) = \frac{1}{\xi_i^{(l)}} e^{-\frac{\eta_i}{\xi_i^{(l)}}}. \quad (4.3.28)$$

Характеристическая функция, соответствующая распределению (3.3.28), имеет вид:

$$\theta_{\eta_i}(V) = \frac{1}{1 - jV\xi_i^{(l)}}. \quad (4.3.29)$$

Обозначив

$$g = \frac{1}{\xi_i^{(l)}} - \frac{1}{\xi_i^{(k)}}, \quad (4.3.30)$$

найдем характеристическую функцию величины  $g\eta_i$ :

$$\theta_{g\eta} = \frac{1}{1 - jvg_i\xi_i^{(l)}}. \quad (4.3.31)$$

Характеристическая функция для  $u$  определяется как характеристическая функция суммы независимых случайных величин:

$$\theta_u(V) = \prod_{i=1}^N \frac{1}{1 - jvg_i\xi_i^{(l)}}. \quad (4.3.32)$$

Преобразовав (3.3.32) по Фурье, находим плотность вероятности:

$$W\left(\frac{u}{l}\right) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \prod_{i=1}^N \frac{1}{1 - jv\xi_i^{(l)}g_i} \right) e^{-jvu} dv. \quad (4.3.33)$$

Обозначим

$$\xi_i = \frac{1}{\xi_i^{(l)}g_i} \quad (4.3.34)$$

и перепишем выражение (3.3.33):

$$W\left(\frac{u}{l}\right) = \frac{1}{2\pi} \int_{-\infty}^{\infty} \left( \prod_{i=1}^N \frac{\xi_i}{\xi_i - jv} \right) e^{-jvu} dv. \quad (4.3.35)$$



Для вычисления полученного интеграла (4.3.35) рассмотрим типовые практически важные ситуации и примем ряд предположений. Будем считать, что каждое из распознаваемых РЛИ: 1-е и  $k$ -е в общем случае содержат  $m_{\text{б}}^{(j)}$  ( $j = 1, M$ ) отсчетов, вызванных наличием «блестящих» точек,  $m_{\text{п}}^{(j)}$  ( $j = 1, M$ ) отсчетов, определяющихся диффузионными отражениями от распределённой поверхности ПРЦ и  $m_{\text{м}}^{(j)}$  ( $j = 1, M$ ) отсчетов от подстилающей поверхности. Отсчеты от «блестящих» точек на каждом из РЛИ отличаются по величине ЭПР как между собой, так и между отсчетами от «блестящих» точек, распределённой и подстилающей поверхности на «своем» и конкурирующем РЛИ. Иначе ведут себя отсчеты, соответствующие распределённой поверхности: в пределах «своего» РЛИ они не отличаются по величине ЭПР и, следовательно, отличаются от отсчетов распределённой поверхности другого РЛИ на постоянную величину. Относительно подстилающей поверхности могут быть высказаны аналогичные соображения. Из сказанного следует, что при наличии  $m_{\text{кп}}$  отсчетов распределённой поверхности на одинаковых позициях двух РЛИ такова же кратность полюсов подынтегрального выражения. Если число элементов двух РЛИ, имеющих одинаковые расположения и «занятых» МП, равно  $m_{\text{км}}$ , то в подынтегральном выражении столько же одинаковых полюсов, разумеется, отличающихся по значению от «полюсов подстилающей поверхности».

При выполнении принятых предположений вычислим интеграл (4.3.35):

$$\begin{aligned}
 W(u/l) = & \sum_{q \in M_{\text{б}}} \xi_q e^{-\xi_q u} \prod_{\substack{i \in M_{\text{б}} \\ i \neq q}} \frac{\xi_i}{\xi_i - \xi_q} l(\xi_q) + \\
 & + \left\{ \frac{1}{(m_{\text{кп}} - 1)!} \lim_{p \rightarrow \xi_{\text{п}}} \frac{d^{m_{\text{кп}} - 1}}{dp^{m_{\text{кп}} - 1}} \left[ e^{-pu} \frac{\xi_{\text{п}}^{m_{\text{кп}}} \xi_M^{m_{\text{км}}}}{(\xi_M - p)^{m_{\text{км}}}} \prod_{i \in M_{\text{б}}} \left( \frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(\xi_{\text{п}}) + \quad \text{при } u > 0 \quad (4.3.36) \\
 & + \left\{ \frac{1}{(m_{\text{км}} - 1)!} \lim_{p \rightarrow \xi_M} \frac{d^{m_{\text{км}} - 1}}{dp^{m_{\text{км}} - 1}} \left[ e^{-pu} \frac{\xi_{\text{п}}^{m_{\text{кп}}} \xi_M^{m_{\text{км}}}}{(\xi_{\text{п}} - p)^{m_{\text{км}}}} \prod_{i \in M_{\text{б}}} \left( \frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(\xi_M);
 \end{aligned}$$

$$\text{где } l(x) = \begin{cases} 1 & x > 0; \\ 0 & x < 0. \end{cases}$$

В выражении (4.3.36) суммирование производится лишь по тем индексам, для которых  $\xi_q > 0$  ( $q \in M_{\text{б}}$ , причем  $M_{\text{б}}$  — множество тех позиций 1-го и  $k$ -го РЛИ, на которых расположены «блестящие точки», другими словами, множество некротных полюсов.

При  $u < 0$  интеграл (3.3.35) выглядит аналогично.

$$\begin{aligned}
 W(u/l) = & \sum_{q \in M_{\text{б}}} \xi_q e^{-\xi_q u} \prod_{\substack{i \in M_{\text{б}} \\ i \neq q}} \frac{\xi_i}{\xi_i - \xi_q} l(-\xi_q) + \\
 & + \left\{ \frac{1}{(m_{\text{кп}} - 1)!} \lim_{p \rightarrow \xi_{\text{п}}} \frac{d^{m_{\text{кп}} - 1}}{dp^{m_{\text{кп}} - 1}} \left[ e^{-pu} \frac{\xi_{\text{п}}^{m_{\text{кп}}} \xi_M^{m_{\text{км}}}}{(\xi_M - p)^{m_{\text{км}}}} \prod_{i \in M_{\text{б}}} \left( \frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(-\xi_{\text{п}}) + \quad (4.3.37) \\
 & + \left\{ \frac{1}{(m_{\text{км}} - 1)!} \lim_{p \rightarrow \xi_M} \frac{d^{m_{\text{км}} - 1}}{dp^{m_{\text{км}} - 1}} \left[ e^{-pu} \frac{\xi_{\text{п}}^{m_{\text{кп}}} \xi_M^{m_{\text{км}}}}{(\xi_M - p)^{m_{\text{км}}}} \prod_{i \in M_{\text{б}}} \left( \frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(-\xi_M).
 \end{aligned}$$

В последнем выражении суммирование производится лишь по тем индексам, для которых  $\zeta_i < 0$ .

После подстановки (4.3.36) и (4.3.37) в (4.3.27) найдем формулу для вычисления вероятности превышения ложным выходным эффектом истинного.

а) при  $Q > 0$ :

$$p_l^k = \sum_{q \in M_b} e^{-\xi_q Q} \prod_{\substack{i \in M_b \\ i \neq q}} \frac{\xi_i}{\xi_i - \xi_q} l(\xi_q) + \\ + \left\{ \frac{1}{(m_{k\Pi} - 1)!} \lim_{p \rightarrow \xi_{\Pi}} \frac{d^{m_{k\Pi}-1}}{dp^{m_{k\Pi}-1}} \left[ e^{-\xi_{\Pi} Q} \frac{\xi_{\Pi}^{m_{k\Pi}-1} \xi_M^{m_{kM}}}{(\xi_M - p)^{m_{kM}}} \prod_{i \in M_b} \left( \frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(\xi_{\Pi}) + \\ + \left\{ \frac{1}{(m_{kM} - 1)!} \lim_{p \rightarrow \xi_M} \frac{d^{m_{kM}-1}}{dp^{m_{kM}-1}} \left[ e^{-\xi_M Q} \frac{\xi_{\Pi}^{m_{k\Pi}} \xi_M^{m_{kM}-1}}{(\xi_M - p)^{m_{kM}}} \prod_{i \in M_b} \left( \frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(\xi_M), \quad (4.3.38)$$

где  $r$  – номера тех индексов, для которых  $\zeta_q > 0$ .

б) при  $Q < 0$ :

$$p_l^k = \sum_{q \in M_b} (1 - e^{-\xi_q Q}) \prod_{\substack{i \in M_b \\ i \neq q}} \frac{\xi_i}{\xi_i - \xi_q} l(-\xi_q) + \sum_{r \in M_b} \prod_{i \in M_b} \frac{\xi_i}{\xi_i - \xi_r} l(\xi_r) + \\ + \left\{ \frac{1}{(m_{k\Pi} - 1)!} \lim_{p \rightarrow \xi_{\Pi}} \frac{d^{m_{k\Pi}-1}}{dp^{m_{k\Pi}-1}} \left[ (1 - e^{-\xi_{\Pi} Q}) \frac{\xi_{\Pi}^{m_{k\Pi}-1} \xi_M^{m_{kM}}}{(\xi_M - p)^{m_{kM}}} \prod_{i \in M_b} \left( \frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(-\xi_{\Pi}) + \\ + \left\{ \frac{1}{(m_{kM} - 1)!} \lim_{p \rightarrow \xi_M} \frac{d^{m_{kM}-1}}{dp^{m_{kM}-1}} \left[ (1 - e^{-\xi_M Q}) \frac{\xi_{\Pi}^{m_{k\Pi}} \xi_M^{m_{kM}-1}}{(\xi_M - p)^{m_{kM}}} \prod_{i \in M_b} \left( \frac{\xi_i}{\xi_i - p} \right) \right] \right\} l(-\xi_M). \quad (4.3.39)$$

Вычисления по приведенным формулам неоправданно громоздки и могут быть существенно упрощены в соответствии со следующими предположениями:

а) размер фрагмента РЛИ выбирается таким образом, чтобы не превышать максимальных размеров РЛИ ПРЦ, что заведомо ограничивает возможное число отсчетов, приходящихся на подстилающую поверхность;

б) отношение сигнал/фон в каждом элементе разрешения, содержащем отсчеты, принадлежащие цели, для реальных РЛИ составляет не менее 10 дБ;

в) в «блестящих» точках РЛИ ПРЦ сосредоточено, по крайней мере, 80 % ее ЭПР.

При этом расчетная формула для определения вероятности правильной классификации ПРЦ  $k$ -го класса выглядит следующим образом:

$$p(l/l) \geq 1 - \sum_{k=1}^M \sum_{q \in M_b} e^{-\xi_q^{lk} Q} \prod_{\substack{i \in M_b \\ i \neq q}} \frac{\xi_i^{lk}}{\xi_i^{lk} - \xi_q^{lk}} l(\xi_q^{lk});$$

при  $Q > 0$

$$p(l/l) \geq 1 - \sum_{k=1}^M \left\{ \sum_{q \in M_b} (1 - e^{-\xi_q^{lk} Q}) \prod_{\substack{i \in M_b \\ i \neq q}} \frac{\xi_i^{lk}}{\xi_i^{lk} - \xi_q^{lk}} l(-\xi_q^{lk}) + \right. \\ \left. + \sum_{q \in M_b} \prod_{i \in M_b} \frac{\xi_i^{lk}}{\xi_i^{lk} - \xi_q^{lk}} l(\xi_q^{lk}) \right\}; \quad (4.3.40)$$

при  $Q < 0$ .

В выражении (3.3.40) приняты следующие обозначения:

$$\xi_i^{lk} = 1 - \frac{\xi_i^l}{\xi_i^k}; \quad Q = \sum_{i=1}^N \ln \frac{\xi_i^k}{\xi_i^l}.$$

Предположим, что РЛИ ПРЦ  $k$ -го класса представляет собой совокупность  $n_k$  экспоненциально распределенных независимых отсчетов, принадлежащих цели, и, соответственно,  $m - n_k$  отсчетов, созданных только шумом, причем, «целевые» отсчеты имеют одинаковую между собой ЭПР, равную  $\sigma_k/n_k$  ( $\sigma_k$  — интегральная ЭПР цели  $k$ -го класса, а параметр экспоненциального распределения «шумовых» отсчетов равен  $\sigma_{\text{ш}}$ ).

В этом случае оптимальный алгоритм классификации может быть синтезирован по критерию максимального правдоподобия, в соответствии с которым решения принимается в пользу той гипотезы, для которой отношение правдоподобия максимально:

$$\hat{k} = \operatorname{argmax} \Delta(n_k, \sigma_k) = \operatorname{argmax} \frac{W(\bar{\eta}/n_k, \sigma_k)}{W(\bar{\eta}/\text{шум})}, \quad (4.3.41)$$

где  $W(\bar{\eta}/n_k, \sigma_k)$  — плотность вероятности вектора наблюдаемых данных  $\bar{\eta}$  при наличии цели  $k$ -го класса;  $W(\bar{\eta}/\text{шум})$  — плотность вероятности вектора наблюдаемых данных  $\bar{\eta}$  при наличии только шума.

При экспоненциальном распределении вероятностей отсчетов РЛИ отношение правдоподобия может быть записано в следующем виде:

$$\Delta(n, \sigma) = \frac{1}{\left(1 + \frac{\sigma_k}{\sigma_{\text{ш}} n_k}\right)^{n_k}} \exp \left\{ \frac{\frac{\sigma_k}{n_k \sigma_{\text{ш}}}}{1 + \frac{\sigma_k}{n_k \sigma_{\text{ш}}}} \sum_{n_k} x_i \right\}, \quad (4.3.42)$$

где  $x_i = \frac{\eta_i}{\sigma_{\text{ш}}}$ .

Вероятность принятия  $k$ -й гипотезы при истинной гипотезе с номером 1 находится из условия:

$$P\{I(k) > I(l)\} = P \left\{ \frac{\frac{\sigma_k}{n_k \sigma_{\text{ш}}}}{1 + \frac{\sigma_k}{n_k \sigma_{\text{ш}}}} \sum_{n_k} x_i - \frac{\frac{\sigma_l}{n_l \sigma_{\text{ш}}}}{1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}}} \sum_{n_l} x_i > \ln \frac{\left(1 + \frac{\sigma_k}{n_k \sigma_{\text{ш}}}\right)^{n_k}}{\left(1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}}\right)^{n_l}} \right\}. \quad (4.3.43)$$

В рассматриваемой ситуации гипотезы могут быть упорядочены следующим образом: с возрастанием номера гипотезы как размеры ПРЦ, так и ее интегральная ЭПР уменьшаются, то есть при  $K > 1$  считаем, что  $n_k < n_l$  и наоборот. Введем обозначения:

$$\beta_k = \frac{\frac{\sigma_k}{n_k \sigma_{\text{ш}}}}{1 + \frac{\sigma_k}{n_k \sigma_{\text{ш}}}};$$

при  $k > l$  ( $n_l > n_k$ ),

$$y = (\beta_k - \beta_l) \sum_{n_k} x_i - \beta_l \sum_{n_l - n_k} x_i; \quad (4.3.44)$$

при  $k < l$  ( $n_k > n_l$ ),

$$y = (\beta_k - \beta_l) \sum_{n_l} x_i + \beta_k \sum_{n_k - n_l} x_i.$$

Поскольку справедливой считается 1-я гипотеза, в случае «а» плотность вероятности случайной величины  $x_i$  равна

$$W(x_i) = \frac{1}{1 + \frac{\sigma_l}{n_l \sigma_{III}}} \exp \left( -\frac{x_i}{1 + \frac{\sigma_l}{n_l \sigma_{III}}} \right) \text{ при } x_i > 0 \quad (4.3.45)$$

в первой и второй суммах, а в случае «б» плотность вероятности в первой сумме определяется в соответствии с выражением (4.3.45), а во второй сумме:

$$W(x_i) = \exp(-x_i).$$

После определения характеристической функции и плотности вероятности случайной величины  $y$  найдем расчетные выражения для вероятностей ошибочных и верных решений относительно принятия  $k$ -й гипотезы при истинной гипотезе с номером 1.

При  $k > 1; \xi_1^{kl} > 0; Q > 0$ :

$$p_I^k = \frac{1}{(n_l - n_k - 1)!} \lim_{p \rightarrow \frac{1}{\xi_2^l}} \frac{d^{n_l - n_k - i}}{dp^{n_l - n_k - l}} \left\{ \frac{(-1)e^{pQ}}{p(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k - 1} \left(p \frac{1}{\xi_1^{kl}}\right)} \right\}.$$

При  $k > 1; \xi_1^{kl} > 0; Q < 0$ :

$$p_I^k = \frac{1}{(n_k - 1)!} \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k}} \lim_{p \rightarrow \frac{1}{\xi_1^{kl}}} \frac{d^{n_k - 1}}{dp^{n_k - 1}} \left\{ \frac{1 - e^{pQ}}{\left(p + \frac{1}{\xi_2^l}\right)^{n_l - n_k}} \right\} +$$

$$+ \frac{1}{(n_l - n_k - 1)!} \frac{(-1)^k}{(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k}} \lim_{p \rightarrow \frac{1}{\xi_2^l}} \frac{d^{n_l - n_k - 1}}{dp^{n_l - n_k - 1}} \left\{ \frac{1}{\left(p - \frac{1}{\xi_1^{kl}}\right)^{n_k}} \right\}.$$

При  $k > 1; \xi_1^{kl} < 0; Q > 0$ :

$$p_I^k = \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k}} \left\{ \frac{1}{(n_k - 1)!} \lim_{p \rightarrow \frac{1}{|\xi_1^{kl}|}} \frac{d^{n_k - 1}}{dp^{n_k - 1}} \left[ \frac{e^{pQ}}{p \left(p + \frac{1}{\xi_2^l}\right)^{n_l - n_k}} \right] \right\} +$$

$$+ \frac{1}{(n_l - n_k - 1)!} \lim_{p \rightarrow \frac{1}{\xi_2^l}} \frac{d^{n_l - n_k - 1}}{dp^{n_l - n_k - 1}} \left[ \frac{e^{pQ}}{p \left(p - \frac{1}{\xi_1^{kl}}\right)^{n_k}} \right].$$

При  $k > 1$ ;  $\xi_1^{kl} < 0$ ;  $Q < 0$ :

Результат – предыдущая формула при  $Q = 0$ .

При  $k < 1$ ;  $\xi_1^{kl} > 0$ ;  $Q > 0$ :

$$p_I^k = 0.$$

При  $k < 1$ ;  $\xi_1^{kl} > 0$ ;  $Q < 0$ :

$$p_I^k = \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_l} (\xi_3^k)^{n_k - n_l}} \left\{ \frac{1}{(n_l - 1)!} \lim_{p \rightarrow \frac{1}{\xi_1^{kl}}} \frac{d^{n_l - 1}}{dp^{n_l - 1}} \left[ \frac{1 - e^{pQ}}{p \left( p - \frac{1}{\xi_3^k} \right)^{n_k - n_l}} \right] + \right. \\ \left. + \frac{1}{(n_k - n_l - 1)!} \lim_{p \rightarrow \frac{1}{\xi_3^k}} \frac{d^{n_k - n_l - 1}}{dp^{n_k - n_l - 1}} \left[ \frac{1 - e^{pQ}}{p \left( p - \frac{1}{\xi_1^{kl}} \right)^{n_l}} \right] \right\}.$$

При  $k < 1$ ;  $\xi_1^{kl} < 0$ ;  $Q > 0$ :

$$p_I^k = \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k}} \left\{ \frac{1}{(n_k - 1)!} \lim_{p \rightarrow \frac{1}{|\xi_1^{kl}|}} \frac{d^{n_k - 1}}{dp^{n_k - 1}} \left[ \frac{-e^{pQ}}{p \left( p + \frac{1}{\xi_2^l} \right)^{n_l - n_k}} \right] + \right. \\ \left. + \frac{1}{(n_l - n_k - 1)!} \lim_{p \rightarrow \frac{-1}{\xi_2^l}} \frac{d^{n_l - n_k - 1}}{dp^{n_l - n_k - 1}} \left[ \frac{-e^{pQ}}{p \left( p - \frac{1}{\xi_1^{kl}} \right)^{n_k}} \right] \right\}.$$

При  $k < 1$ ;  $\xi_1^{kl} < 0$ ;  $Q < 0$ :

$$p_I^k = \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_l} (\xi_3^k)^{n_k - n_l}} \left\{ \frac{1}{(n_k - n_l - 1)!} \lim_{p \rightarrow \frac{1}{\xi_3^k}} \frac{d^{n_k - n_l - 1}}{dp^{n_k - n_l - 1}} \left[ \frac{1 - e^{pQ}}{p \left( p - \frac{1}{\xi_1^{kl}} \right)^{n_l}} \right] + \right. \\ \left. + \frac{(-1)^{n_k}}{(\xi_1^{kl})^{n_k} (\xi_2^l)^{n_l - n_k}} \left\{ \frac{1}{(n_k - 1)!} \lim_{p \rightarrow \frac{1}{|\xi_1^{kl}|}} \frac{d^{n_k - 1}}{dp^{n_k - 1}} \left[ \frac{1}{p \left( p + \frac{1}{\xi_2^l} \right)^{n_l - n_k}} \right] + \right. \right. \\ \left. \left. + \frac{1}{(n_l - n_k - 1)!} \lim_{p \rightarrow \frac{-1}{\xi_2^l}} \frac{d^{n_l - n_k - 1}}{dp^{n_l - n_k - 1}} \left[ \frac{1}{p \left( p - \frac{1}{\xi_1^{kl}} \right)^{n_k}} \right] \right\} \right\}. \quad (4.3.46)$$



При записи выражения (4.3.46) использованы следующие обозначения:

$$\xi_1^{kl} = \frac{1}{1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}}} \frac{1}{\beta_k - \beta_l};$$

$$\xi_2^l = \left( \frac{\sigma_l}{n_l \sigma_{\text{ш}}} \right)^{-1}; \quad \sigma_3^k = (\beta_k)^{-1}.$$

Существенного упрощения вычислений можно достичь при условии, что количество слагаемых в первой и второй суммах выражения (4.3.44) достаточно велико, чтобы считать справедливым предположение о нормализации случайной величины  $y$ . В этом случае статистика (4.3.44) гауссова и имеет следующие параметры.

При  $k > 1$

$$M\{y\} = \left( 1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}} \right) (\beta_k n_k - \beta_l n_l);$$

$$D\{y\} = \left( 1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}} \right)^2 (n_k \beta_k^2 - 2n_k \beta_k \beta_l + n_l \beta_l^2).$$

При  $k < 1$

$$M\{y\} = (\beta_k - \beta_l) n_l \left( 1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}} \right) + \beta_k (n_l - k_k);$$

$$D\{y\} = \left( 1 + \frac{\sigma_l}{n_l \sigma_{\text{ш}}} \right)^2 (\beta_k - \beta_l)^2 n_k + \beta_k^2 (n_k - n_l).$$

Оценки вероятностей ошибочных и верных решений находится из очевидного соотношения:

$$p_l^k = 1 - \Phi \left\{ \frac{Q - M}{D^{1/2}} \right\}.$$

#### 4.3.3. Оценка эффективности при корнях большой кратности

Методологическая основа расчета информативности та же, что и в разделе 4.1.

Для расчета вероятности  $p_l^k$  воспользуемся предположением, о том, что компоненты (квадратурные составляющие на выходе линейной части устройства формирования РЛИ), образующие в результате вектор отсчетов радиолокационного портрета  $\bar{\eta}$ , статистически независимы и нормальны. В этом случае решение принимается в соответствии с алгоритмом (4.3.1), а вероятности  $p_l^k$  находятся в соответствии со следующим приближенным выражением:

$$p_l^k = \exp \left\{ \mu_l^k(S) - S \dot{\mu}_l^k(S) \right\}; \quad (4.3.47)$$

где

$$\mu_l^k(S) = \ln \int \dots \int P^S(\bar{\eta}/k) P^{1-S}(\bar{\eta}/l) d\bar{\eta} =$$

$$= \frac{1}{2} \sum_{i=1}^N \left\{ \frac{S(S-1)(m_{ki} - m_{li})^2}{S\sigma_{li}^2 + (1-S)\sigma_{ki}^2} \ln \frac{(\sigma_{ki}^2)^{1-S} (\sigma_{li}^2)^S}{S\sigma_{li}^2 + (1-S)\sigma_{ki}^2} \right\}, \quad (4.3.48)$$

причем  $S$  выбирается из условия  $\mu_l^k(S) = 0$ .

В последнем выражении:  $m_{ki}$  — математическое ожидание, а  $\sigma_{ki}^2$  — дисперсия  $i$ -й компоненты признака при наблюдении ПРЦ  $k$ -го класса. Для случая, аналогичного анализу алгоритма (4.3.1):

$$m_{ki} = 0 \quad (k = 1, M; i = 1, N); \sigma_{ki}^2 = \xi_i^k. \quad (4.3.49)$$

#### 4.4. Анализ алгоритмов классификации по РЛИ ПРЦ

Расчет по формулам (4.3.38)–(4.3.39) для трех упомянутых типов ПРЦ позволяет получить следующую матрицу вероятностей правильных и ошибочных решений:

$$P = \begin{pmatrix} P(1/1) & P(2/1) & P(3/1) \\ P(1/2) & P(2/2) & P(3/2) \\ P(1/3) & P(2/3) & P(3/3) \end{pmatrix} = \begin{pmatrix} 0,977 & 0,021 & 0,002 \\ 0,013 & 0,964 & 0,023 \\ 0,010 & 0,038 & 0,952 \end{pmatrix}, \quad (4.4.1)$$

где  $P(1/k)$  — вероятность принятия решения в пользу 1-го класса при истинном —  $k$ . Номера соответствуют: 1 — «большая» цель, 2 — цель «среднего» класса и 3 — «малая» цель.

Результаты приведены для случая, когда какие-либо искажения радиолокационных портретов отсутствуют, а удельная ЭПР подстилающей поверхности (–30 дБ) настолько мала, что ее величина практически не оказывает влияния на качество классификации.

Для анализа алгоритмов классификации в более широком спектре условий наблюдения, по-видимому, нет альтернативы методам статистического моделирования. В данном разделе приведены результаты такого моделирования для анализа эффективности классификации трех типов ПРЦ при двух вариантах разрешающей способности (12 и 24 м), трех значениях удельной ЭПР МП (–30, –20 и –10 дБ), и трех ракурсах наблюдения ПРЦ (0°, 45° и 90°). Примеры РЛИ показаны на рис. 4.10, а матрицы вероятностей — в табл. 4.1.

Таблица 4.1

Матрицы вероятностей правильных решений

| № п/п | Разрешение (м) | ЭПР МП (дБ) | Ракурс | $P$   |
|-------|----------------|-------------|--------|---|
| 1     | 2              | 3           | 4      | 5   |
| 1     | 12             | –30         | 0°     | $\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$           |
|       |                |             | 45°    | $\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0,1 & 0,9 \end{pmatrix}$       |
|       |                |             | 90°    | $\begin{pmatrix} 0,95 & 0,05 & 0 \\ 0 & 1 & 0 \\ 0 & 0,1 & 0,9 \end{pmatrix}$ |
| 2     | 12             | –20         | 0°     | $\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0,05 & 0,95 \end{pmatrix}$     |

Окончание табл. 4.1

| 1 | 2  | 3   | 4   | 5   |
|---|----|-----|-----|---|
|   |    |     | 45° | $\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0,1 & 0,9 \end{pmatrix}$               |
|   |    |     | 90° | $\begin{pmatrix} 0,9 & 0,1 & 0 \\ 0 & 1 & 0 \\ 0 & 0,15 & 0,85 \end{pmatrix}$         |
| 3 | 12 | -10 | 0°  | $\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$                   |
|   |    |     | 45° | $\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$                   |
|   |    |     | 90° | $\begin{pmatrix} 0,2 & 0,8 & 0 \\ 0 & 0,35 & 0,65 \\ 0 & 0,2 & 0,8 \end{pmatrix}$     |
| 4 | 24 | -30 | 0°  | $\begin{pmatrix} 1 & 0 & 0 \\ 0 & 0,7 & 0,3 \\ 0 & 0,1 & 0,9 \end{pmatrix}$           |
|   |    |     | 45° | $\begin{pmatrix} 0,95 & 0,05 & 0 \\ 0,1 & 0,85 & 0,05 \\ 0 & 0,1 & 0,9 \end{pmatrix}$ |
|   |    |     | 90° | $\begin{pmatrix} 0,95 & 0,05 & 0 \\ 0 & 0,85 & 0,15 \\ 0 & 0,2 & 0,8 \end{pmatrix}$   |
| 5 | 24 | -20 | 0°  | $\begin{pmatrix} 1 & 0 & 0 \\ 0 & 0,6 & 0,4 \\ 0 & 0,1 & 0,9 \end{pmatrix}$           |
|   |    |     | 45° | $\begin{pmatrix} 0,7 & 0,3 & 0 \\ 0,1 & 0,85 & 0,05 \\ 0 & 0,05 & 0,95 \end{pmatrix}$ |
|   |    |     | 90° | $\begin{pmatrix} 0,95 & 0,05 & 0 \\ 0 & 0,8 & 0,2 \\ 0 & 0,3 & 0,7 \end{pmatrix}$     |
| 6 | 24 | -10 | 0°  | $\begin{pmatrix} 1 & 0 & 0 \\ 0 & 0,3 & 0,7 \\ 0 & 0,1 & 0,9 \end{pmatrix}$           |
|   |    |     | 45° | $\begin{pmatrix} 0,9 & 0,1 & 0 \\ 0,1 & 0,8 & 0,1 \\ 0,05 & 0,3 & 0,65 \end{pmatrix}$ |
|   |    |     | 90° | $\begin{pmatrix} 0,1 & 0,2 & 0,65 \\ 0 & 0,1 & 0,9 \\ 0 & 0,1 & 0,9 \end{pmatrix}$    |




Рис. 4.10. Примеры РЛИ ПРЦ

#### 4.5. Распознавание ПРЦ по данным разных средств наблюдения

В тех случаях, когда по одному вектору наблюдаемых данных требуемая вероятность правильной классификации обеспечена быть не может, встает вопрос об оптимальном использовании совокупности всех данных для принятия решения о классе ПРЦ: разработке соответствующих алгоритмов и анализе их эффективности.

##### 4.5.1. Коллективное распознавание

Один из наиболее простых и эффективных путей повышения качества распознающих систем заключается в коллективном принятии решения путём объединения выводов (голосов), принятых отдельными автоматами, возможно, разной физической природы, например оптическими, тепловыми, телевизионными, радиолокационными и т. п. Другими словами, итоговое решение принимается коллективом решающих правил, между которыми устраивается голосование.

Коллективом, принимающим решения, считаем совокупность автоматов  $R_l$ , ( $L$  – число автоматов, принимающих решения), каждый из которых принимает индивидуальное решение  $S_l$ . В этом случае коллективное решение представляет собой некоторую функцию индивидуальных решений:

$$S = F(S_1, S_2, \dots, S_L; X) \quad (4.5.1)$$

где  $F$  – алгоритм принятия коллективного решения;  $X = (x_1, x_2, \dots, x_n)$  – вектор параметров (признаков) классифицируемых объектов.

Структурная схема алгоритма коллективного принятия решения приведена на рис. 4.11.

Решение  $S$  заключается в выборе номера  $j$  одного из возможных классифицируемых объектов для вектора наблюдаемых данных  $X$ .

Рассмотрим алгоритм голосования. Пусть  $q_j$  – голосующая функция  $j$ -го класса:

$$q_j = \sum_l \mu_l, \quad (4.5.2)$$

где  $\mu_l$  – нормированный вес  $l$ -го решающего правила. Суммирование ведётся по тем  $l$ , для которых  $S_l = j$ .

Решение о принадлежности вектора  $X$  к классу  $A_j$  принимается по следующему правилу:

$$X \in A_{j^*}, \text{ если } q_{j^*} = \max_j q_j. \quad (4.5.3)$$




Рис. 4.11. Алгоритм коллективного принятия решения



Алгоритм коллективного принятия решения может строиться на основе двух принципов: объединение признаков; объединение решений.

В первом случае от  $L$  различных средств наблюдения (СН) в центральный пункт (ЦП) обработки поступают значения признаков, например, данные радиолокационной разведки (РЛР) — отсчеты РЛИ или функции от них; данные радиотехнической разведки (РТР) — параметры разведанных сигналов — мощность, частота, длительность импульсов, период их следования и т.д.; данные радиоразведки (РР) — вид и глубина модуляции РР. При достаточных временных и вычислительных ресурсах традиционное классическое решение задачи классификации обеспечивает достоверность, близкую к оптимальной. В то же время названный подход является чрезвычайно громоздким.

В этом случае целесообразно комплексирование информации на уровне объединения решений, вынесенных отдельными средствами наблюдения, например с использованием правила (3).

Близким к оптимальному будет применение правила взвешенного суммирования [2], содержание которого заключается в следующем. При поступлении в ЦП решения 1-го источника информации ( $l = \overline{1, L}$ ) в пользу  $i$ -го класса для каждого  $j$ -го класса ( $i, j = \overline{1, M}$ ) вычисляется коэффициент, равный:

$$V_{jl} = C_{jl}; \quad C_{jl} = A \lg \frac{P_{ijl}}{P_{il}}, \quad (4.5.4)$$

где 
$$P_{il} = \min_j P_{ijl}; \quad A^{-1} = \max_{i,j,l} \lg \left( \frac{P_{ijl}}{P_{il}} \right),$$

а  $P_{ijl}$  — вероятность вынесения решения в пользу  $i$ -го класса  $l$ -м источником при фактическом наличии ПРЦ  $j$ -го класса. Полученные коэффициенты суммируются

$$V_j = \sum_{l=1}^L V_{jl}; \quad j = \overline{1, M}$$

и принимается решение в пользу класса, для которого величина  $V_j$  максимальна.

Рассмотрим некоторые упрощения алгоритма взвешенного суммирования. Прежде всего проанализируем ситуацию, когда вероятности правильных и ошибочных решений одинаковы для разных СН:

$$P_{ji1} = P_{ji2} = \dots = P_{jiL} = P_0;$$

$$P_{ij1} = P_{ij2} = \dots = P_{ijL} = \frac{1 - P_0}{M - 1}; \quad 1 \neq j; \quad 1, j = \overline{1, M}.$$

В этом случае реализуется процедура «простого голосования», когда решение принимается в пользу того класса, за который «голосует» большинство СН. Названная процедура является оптимальной, если:

- источники информации статистически независимы;
- достоверность источников одинакова;
- вероятности ошибочных решений одинаковы.

Простое голосование представляет собой достаточно эффективную процедуру принятия коллективного решения, если достоверности источников мало отличаются

между собой. Если такое различие существенно, следует использовать правило взвешенного голосования, которое реализуется при выполнении следующего условия:

$$P_{ijl} = \frac{1 - P_{ijl}}{M - 1}; \quad i \neq j; i, j = \overline{1, M}.$$

При этом каждому «голосу» приписывается свой «вес»:

$$C_{ijl} = A \lg \frac{P_{ijl}}{P_{ijl}}; \quad C_{ijl} = 0.$$

#### 4.5.2. Анализ эффективности классификации

С целью получения самых общих представлений о повышении эффективности классификации ПРЦ за счет комплексирования данных от разных средств наблюдения рассмотрим зависимость вероятности правильного распознавания (ВПР) всей системы в целом ( $P_e$ ) от ВПР одного СН ( $P_p$ ) при разном количестве источников информации  $L$ . В частности, на рис. 4.12 приведена названная зависимость для алгоритма простого голосования. Из рисунка следует, что для получения итоговой вероятности  $P_e > 0,9$  при наличии 6 независимых средств наблюдения частная вероятность правильной классификации каждым СН должна быть не менее 0,7. В некоторых случаях процедуры простого голосования снижают итоговую ВПР. Так, например, при объединении трех СН, из которых два имеют ВПР, равную 0,4, а один – 0,9 при простом голосовании  $P_e < 0,7$ , а при взвешенном больше 0,9.




Рис. 4.12. Зависимости вероятности правильного распознавания при простом голосовании от вероятности правильного распознавания при принятии решения по одному наблюдению

Конкретный пример применения алгоритма коллективного распознавания рассмотрим для ситуации объединения данных радиолокационной и радиотехнической разведки. Предположим, что классификатор располагает следующими источниками информации.

1. Станция РТР, определяющая класс ПРЦ по параметрам частотной модуляции принимаемого сигнала, вызванной килевой и бортовой качками ПРЦ при использовании электронной стабилизации луча РЛС.

2. РЛС с синтезированной апертурой, определяющая класс ПРЦ по его радиолокационному изображению. Причем сведения о классе ПРЦ, формируемые РСА могут быть получены неоднократно на разных витках орбиты носителя РСА. Эти сведения считаются статистически независимыми.

Эффективность каждого СН оценивается матрицей вероятностей правильных и ошибочных решений.

$$P = \begin{pmatrix} P_{A/A} & P_{K/A} & P_{Э/A} \\ P_{A/K} & P_{K/K} & P_{Э/K} \\ P_{A/Э} & P_{K/Э} & P_{Э/Э} \end{pmatrix}.$$

Цифровое моделирование алгоритма классификации по данным средств РТР [7], для одной из возможных практических ситуаций, позволило получить следующую матрицу:

$$P = \begin{pmatrix} 0,88 & 0,12 & 0,0 \\ 0,15 & 0,78 & 0,07 \\ 0,0 & 0,28 & 0,72 \end{pmatrix}.$$

Для второго из используемых средств наблюдения – РСА. Выделим две типовых ситуации, исследованных методом статистического моделирования при использовании в качестве прототипа тактико-технических характеристик космического аппарата SEASAT. При высокой эффективности (отношение сигнал/шум на выходе линейной части приемника составляет величину порядка 20 дБ) оценка матрицы вероятностей правильной и ошибочной классификации была получена в следующем виде:

$$P_2^{(1)} = \begin{pmatrix} 0,95 & 0,04 & 0,01 \\ 0,03 & 0,85 & 0,12 \\ 0,00 & 0,09 & 0,91 \end{pmatrix}.$$

При низком отношении сигнал/шум (порядка 14 дБ) оценка матрицы имеет вид:

$$P_2^{(2)} = \begin{pmatrix} 0,65 & 0,22 & 0,13 \\ 0,18 & 0,49 & 0,33 \\ 0,10 & 0,27 & 0,63 \end{pmatrix}.$$

Используя приведенные данные о достоверности различных СН, моделировались разные ситуации коллективного распознавания. Предполагалось, что от каждого источника поступает информация о номере выбранного класса. Сравнивались, два правила принятия решения: простое голосование и взвешенное суммирование, причем при взвешенном суммировании матрицы вероятностей, описывающие эффективность различных средств наблюдения, предполагались известными. Результаты моделирования сведены в табл. 4.2. В первом ее столбце приведены обозначения матриц, вероятностей используемых источников. Цифра перед матрицей указывает на число независимых СН (при моделировании изменялось количество решений, принимаемых на основе РСА).

Из анализа результатов моделирования можно сделать следующие выводы. Если имеются два источника информации с разными матрицами вероятностей верных и ошибочных решений, то при простом голосовании итоговая матрица оказывается

«средней» между исходными матрицами. При взвешенном суммировании итоговая матрица будет, по крайней мере, не хуже, чем любая из исходных. При простом голосовании вероятность ошибки с ростом числа «плохих» источников информации может даже увеличиваться, если в коллективе распознающих автоматов наряду с источником, обладающим высокой достоверностью, присутствуют «плохие» СН, имеющие низкую эффективность классификации.

Правило взвешенного суммирования при тех же условиях обеспечивает гарантированный выигрыш по отношению к самому «хорошему» средству наблюдения, используемому вне коллектива решающих правил. Платой за такой выигрыш является априорное знание достоверности классификации ПРЦ каждым средством наблюдения.

Названные сведения не могут быть получены иначе, чем в результате оценки эффективности каждого классификатора либо по рабочим, либо экспериментальным, либо моделируемым выборкам наблюдаемых данных.

#### 4.6. Методика расчета вероятности правильного распознавания при объединении решений отдельных СН методом простого голосования

Рассмотрим задачу расчета матрицы вероятностей правильных и ошибочных решений при условии, что частные решения выносятся одинаковыми средствами наблюдения методом простого голосования. Число объединяемых решений  $P$ . Априорные вероятности  $P_j$  наблюдения каждого типа ПРЦ известны. Число классов, как и в предыдущих случаях, равно трем. Предположим, что в пользу  $j$ -го класса принято  $n_j$  частных решений. Общее число объединяемых решений —  $N$ . Тогда вероятность возникновения конкретной ситуации совмещения  $n_1, n_2$  и  $n_3 = N - (n_1 + n_2)$  частных решений при наблюдении цели 1-го класса равна

$$C_N^{n_1} C_{N-n_1}^{n_2} P_{1j}^{n_1} P_{2j}^{n_2} P_{3j}^{N-n_1-n_2}.$$

Следует заметить, что при использовании простого голосования могут возникнуть конфликтные ситуации, когда справедливо одно из следующих условий

$$\begin{aligned} n_1 &= n_2 > n_3; \\ n_1 &= n_3 > n_2; \\ n_2 &= n_3 > n_1 \end{aligned} \tag{4.6.1}$$

или 
$$n_1 = n_2 = n_3 = N/3. \tag{4.6.2}$$

Предположим, что разрешение конфликтных ситуаций производится случайным образом. При этом в ситуациях (4.6.1) конфликт между  $j$ -м и  $r$ -м классами разрешается в пользу  $j$ -го класса с вероятностями  $P_{k2}(j/r)$ , которые представлены в виде матрицы:

$$P_{k2} = \begin{pmatrix} 0 & P_{k2}(1/2) & P_{k2}(1/3) \\ P_{k2}(2/1) & 0 & P_{k2}(2/3) \\ P_{k2}(3/1) & P_{k2}(3/2) & 0 \end{pmatrix}$$

для элементов которой справедливо условие

$$P_{k2}(j/r) + P_{k2}(r/j) = 1 \text{ при } j \neq r.$$

Конфликтные ситуации типа (4.6.1) с вероятностью  $P_{кЭ}(j)$  разрешаются в пользу  $j$ -го класса. При этом справедливо равенство

$$P_{к3}(1) + P_{к3}(2) + P_{к3}(3) = 1.$$

Используя введенные предположения, для вероятности вынесения итогового решения в пользу  $j$ -го класса при наблюдении цели  $i$ -го класса можно воспользоваться выражением:

$$P_N(j/i) = \sum_{n_j=0}^N \sum_{n_r=0}^{N-n_j} C_N^{n_j} C_{N-n_j}^{n_r} P_{ji}^{n_j} P_{ri}^{n_r} P_{qi}^{N-n_j-n_r} \cdot A(N, n_j, n_r),$$

где  $r \neq j$ ,  $r \neq q$ ,  $q \neq j$ .

Коэффициент  $A(N, n_j, n_r)$  принимает следующие значения:

$$A(N, n_j, n_r) = \begin{cases} 0 & \text{если } n_j < n_r \quad \text{или } n_j < \frac{N-n_r}{2} \\ 1 & \text{если } n_j > n_r \quad \text{и } n_j > \frac{(N-n_r)}{2} \\ P_{k2}\left(\frac{j}{r}\right) & \text{если } n_j = n_r \quad \text{и } n_j > \frac{N}{3} \\ P_{k2}\left(\frac{j}{q}\right) & \text{если } n_j = \frac{N-n_r}{2} \quad \text{и } n_j > n_r \\ P_{k3}(j) & \text{если } n_j = n_r = \frac{N}{3} \end{cases}.$$

Вероятность правильного распознавания ПРЦ на основе частных решений определяется в соответствии с выражением

$$P_{пр.N} = \sum_{i=1}^3 P_i P_N\left(\frac{1}{i}\right).$$

Таблица 4.2

Матрицы вероятностей правильных решений

| Комбинация СН      | Простое голосование                                | Взвешенное суммирование                            |
|--------------------|--|--|
| $P_1, 1P_2^{(1)}$  | 0,91 0,08 0,01<br>0,09 0,82 0,09<br>0,00 0,18 0,82 | 0,95 0,05 0,00<br>0,03 0,81 0,16<br>0,00 0,03 0,97 |
| $P_1, 2P_2^{(1)}$  | 0,99 0,01 0,00<br>0,02 0,94 0,04<br>0,00 0,05 0,95 | 0,99 0,01 0,00<br>0,01 0,95 0,03<br>0,00 0,05 0,95 |
| $P_1, 6P_2^{(2)}$  | 0,91 0,07 0,02<br>0,07 0,72 0,21<br>0,01 0,14 0,85 | 0,94 0,06 0,00<br>0,05 0,82 0,13<br>0,00 0,13 0,87 |
| $P_1, 10P_2^{(2)}$ | 0,94 0,05 0,01<br>0,05 0,75 0,20<br>0,00 0,10 0,90 | 0,97 0,03 0,00<br>0,04 0,89 0,07<br>0,00 0,13 0,87 |
| $P_1, 14P_2^{(2)}$ | 0,98 0,02 0,00<br>0,03 0,78 0,19<br>0,00 0,06 0,94 | 0,98 0,02 0,00<br>0,02 0,91 0,07<br>0,00 0,07 0,93 |



#### **4.7. Литература к главе 4**

1. Ван Трис Г. Теория обнаружения, оценок и модуляции: в 3 т. / Г. Ван Трис. М.: Сов. радио, 1972. т. 1. 744 с.
2. Растрингин Л.А. Метод коллективного распознавания / Л.А. Растрингин, Р.Х. Эринштейн. М.: Энергоиздат, 1981. 80 с.
3. Корн Г. Справочник по математике для научных работников и инженеров / Г. Корн, Т. Корн. М.: Наука, 1977. 832 с.
4. Ван Трис Г. Теория обнаружения, оценок и модуляции. В 3 т. Т. 3. / Г. Ван Трис. М.: Сов. радио. 1977. т. 3. 664 с.
5. Терраин Ч.У. Алгоритмы анализа изображений, основанные на статистических моделях / Ч.У. Терраин, Т.Ф. Куатьери, Д.Е. Даржон. ТИИЭР. 1986. т. 72. № 4. С. 4-26.
6. Л.Г. Доросинский. Использование граничных соотношений Кайлата для оценки эффективности классификации сигналов. 24-я Международная Крымская конференция «СВЧ-техника и телекоммуникационные технологии», Севастополь, 7-13 сентября 2014.
7. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА, формируемых в РСА монография – М.: Издательский дом Академии Естествознания, 2017. – 212 с.
8. Доросинский Л.Г., Трухин М.П. Приём и обработка сигналов от сложных целей: монография. – М.: Издательский дом Академии Естествознания, 2018.-264 с.

---

## 5. КЛАССИФИКАЦИЯ ПРЦ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

### 5.1. Общие принципы построения нейронной сети (НС)

Одним из мощных инструментов, позволяющих эффективно принимать решения при классификации наблюдаемых объектов, являются нейронные сети [1–3], основанные на идее моделирования процессов, происходящих в мозгу человека, поскольку тот факт, что возможности человеческого мозга распознавать объекты находятся вне конкуренции по сравнению с любым сколь угодно мощным вычислительным средством, не вызывает сомнения.

Нервная система и мозг человека состоят из нейронов, соединенных между собой нервными волокнами. Нервные волокна способны передавать электрические импульсы между нейронами. Все процессы передачи раздражений от нашей кожи, ушей и глаз к мозгу, процессы мышления и управления действиями — все это реализовано в живом организме как передача электрических импульсов между нейронами.

Для построения нейронной сети необходимо понимать строение биологического нейрона (рис. 5.1). Каждый нейрон имеет отростки нервных волокон двух типов: дендриты, по которым принимаются импульсы, и единственный аксон, по которому нейрон может передавать импульс. Аксон контактирует с дендритами других нейронов через специальные образования — синапсы, которые влияют на силу импульса.



Рис. 5.1. Строение биологического нейрона

Можно считать, что при прохождении синапса сила импульса меняется в определенное число раз, которое мы будем называть весом синапса. Импульсы, поступившие к нейрону одновременно по нескольким дендритам, суммируются. Если суммарный импульс превышает некоторый порог, нейрон возбуждается, формирует собственный импульс и передает его далее по аксону. Важно отметить, что веса синапсов может изменяться со временем, а значит меняется и поведение соответствующего нейрона.

Нетрудно построить математическую модель описанного процесса.

На рис. 5.2 изображена модель нейрона с тремя входами (дендритами); синапсы этих дендритов имеют веса  $w_1$ ,  $w_2$ ,  $w_3$ . Пусть к синапсам поступают импульсы силы  $x_1$ ,  $x_2$ ,  $x_3$  соответственно, тогда после прохождения синапсов и дендритов к нейрону

поступают импульсы  $w_1x_1, w_2x_2, w_3x_3$ . Нейрон преобразует полученный суммарный импульс  $x = w_1x_1 + w_2x_2 + w_3x_3$  в соответствии с некоторой передаточной функцией  $f(x)$ . Сила выходного импульса равна

$$y = f(x) = f(w_1x_1 + w_2x_2 + w_3x_3).$$




Рис. 5.2. Модель нейрона

Таким образом, нейрон полностью описывается своими весами  $w_k$  и передаточной функцией  $f(x)$ . Получив набор чисел (вектор)  $x_k$  в качестве входов, нейрон выдает некоторое число  $y$  на выходе.

*Искусственная нейронная сеть (ИНС)* — это набор нейронов, соединенных между собой. Как правило, передаточные функции всех нейронов в нейронной сети фиксированы, а веса являются параметрами нейронной сети и могут изменяться. Некоторые входы нейронов помечены как внешние входы нейронной сети, а некоторые выходы — как внешние выходы нейронной сети. Подавая любые числа на входы нейронной сети, мы получаем какой-то набор чисел на выходах нейронной сети. Таким образом, работа нейронной сети состоит в преобразовании входного вектора в выходной вектор, причем это преобразование задается весами нейронной сети.

Практически любую задачу можно свести к задаче, решаемой с помощью нейронной сети. В качестве примера сформулируем в терминах нейронной сети задачу распознавания рукописных букв.

Исходным двумерным полем данных является растровое черно-белое изображение буквы размером  $30 \times 30$  пикселей (входной вектор из 900 двоичных символов  $30 \times 30 = 900$ ). Требуется определить, какая это буква (в алфавите 33 буквы). Задача заключается в том, чтобы построить нейронную сеть с 900 входами и 33 выходами, которые помечены буквами. Если на входе нейронной сети присутствует изображение буквы «А», то максимальное значение выходного сигнала достигается на выходе «А». Так же нейронная сеть работает для всех 33 букв.

Поясним, зачем требуется выбирать выход нейронной сети с максимальным уровнем сигнала. Дело в том, что уровень выходного сигнала, как правило, может принимать любые значения из какого-то отрезка. Однако в данной задаче нас интересует не аналоговый ответ, а всего лишь номер категории (номер буквы в алфавите). Поэтому используется следующий подход: каждой категории сопоставляется свой выход, а ответом нейронной сети считается та категория, на чьем выходе уровень сигнала максимален. В определенном смысле уровень сигнала на выходе «А» — это достоверность того, что на вход нейронной сети была подана рукописная буква «А».

Теперь, когда стало ясно, что именно мы хотим построить, можем переходить к вопросу, как строить такую нейронную сеть. Этот вопрос решается в два этапа:

- 1) выбор типа (архитектуры) нейронной сети;
- 2) подбор весов (обучение) нейронной сети.

На первом этапе следует выбрать следующее:

- какие нейроны мы хотим использовать (число входов, передаточные функции);
- каким образом следует соединить их между собой;
- что взять в качестве входов и выходов нейронной сети.

Для решения данных задач — существует несколько десятков различных нейросетевых архитектур, причем эффективность многих из них доказана математически. Наиболее популярные и изученные архитектуры — это многослойный перцептрон, нейронная сеть с общей регрессией, нейронная сеть Кохонена и другие.

На втором этапе нам следует «обучить» выбранную нейронную сеть, то есть подобрать такие значения ее весов, чтобы она выдавала требуемый результат. В используемых на практике нейронных сетях количество весов может составлять несколько десятков тысяч, поэтому обучение — действительно сложный процесс. Для многих архитектур разработаны специальные алгоритмы обучения, которые позволяют настроить веса нейронной сети определенным образом. Наиболее популярный из таких алгоритмов основан на методе обратного распространения ошибки (Error Back Propagation), который используется, например, для обучения перцептрона.

Обучение нейронной сети заключается в том, чтобы на определенное воздействие она выдавала «правильную» информацию. Этот процесс очень похож на обучение ребенка алфавиту. Показав ребенку изображение буквы А, мы спрашиваем его: «Какая это буква?» Если ответ неверен, мы сообщаем ребенку тот ответ, который хотели бы от него получить: «Это буква А». Ребенок запоминает пример вместе с верным ответом, т. е. в его памяти происходят некоторые изменения в нужном направлении. Мы будем повторять процесс предъявления букв снова и снова до тех пор, пока все 33 буквы не будут твердо запомнены. Такой процесс называют «обучение с учителем».

При обучении нейронной сети мы действуем совершенно аналогично. Имеется некоторая база данных, содержащая примеры (набор рукописных изображений букв). Предъявляя изображение буквы «А» на вход нейронной сети, мы получаем от нее некоторый ответ, не обязательно верный. Нам известен и верный (желаемый) ответ — в данном случае нужно, чтобы на выходе нейронной сети с меткой «А» уровень сигнала был максимален. Обычно в качестве желаемого выхода в задаче классификации берут набор (1, 0, 0, ...), где 1 стоит на выходе с меткой «А», а 0 — на всех остальных выходах. Вычисляя разность между желаемым ответом и реальным ответом сети, мы получаем 33 числа — *вектор ошибки*. Алгоритм обратного распространения ошибки — это набор формул, который позволяет по вектору ошибки вычислить требуемые поправки для весов нейронной сети. Одну и ту же букву (а также различные изображения одной и той же буквы) мы можем предъявлять нейронной сети много раз. В этом смысле обучение скорее напоминает повторение упражнений в спорте — тренировку. Блок-схема процесса обучения нейронной сети приведена на рис. 5.3.




Рис. 5.3. Блок-схема процесса обучения нейронной сети

После многократного предъявления примеров веса нейронной сети стабилизируются, причем нейронная сеть дает правильные ответы на все (или почти все) примеры из базы данных. В таком случае говорят, что «нейронная сеть выучила все примеры», «нейронная сеть обучена» или «нейронная сеть натренирована». В программных реализациях можно видеть, что в процессе обучения величина ошибки (сумма квадратов ошибок по всем выходам) постепенно уменьшается. Когда величина ошибки достигает нуля или приемлемого малого уровня, тогда тренировку останавливают, а полученную нейронную сеть считают натренированной и готовой к применению на новых данных.

Важно отметить, что вся информация, которую нейронная сеть имеет о задаче, содержится в наборе примеров. Поэтому качество обучения нейронной сети напрямую зависит от количества примеров в обучающей выборке, а также от того, насколько полно эти примеры описывают данную задачу. Так, например, бессмысленно использовать нейронную сеть для предсказания финансового кризиса, если в обучающей выборке кризисов не представлено. Считается, что для полноценной тренировки нейронной сети требуется хотя бы несколько десятков (а лучше сотен) примеров.

После того как нейронная сеть обучена, мы можем применять ее для решения полезных задач. Важнейшая особенность человеческого мозга состоит в том, что, однажды обучившись определенному процессу, он может верно действовать и в тех ситуациях, в которых он не бывал в процессе обучения. Например, мы можем читать почти любой почерк, даже если видим его первый раз в жизни. Так же и «хорошо обученная» нейронная сеть, может с большой вероятностью правильно реагировать на новые, не предъявленные ей ранее данные. Например, мы можем нарисовать букву «А» другим почерком, а затем предложить нашей нейронной сети классифицировать новое изображение. Веса обученной нейронной сети хранят достаточно много информации о сходстве и различиях букв, поэтому мы можем рассчитывать на правильный ответ и для нового варианта изображения.

## 5.2. Алгоритм обратного распространения ошибки

Рассмотрим более подробно упомянутый выше способов алгоритмической реализации нейронной сети — алгоритм обратного распространения ошибки. Названный алгоритм является, пожалуй, наиболее широко распространенным алгоритмом



обучения многослойных нейронных сетей. Формулу, описывающую функционирование нейрона, запишем в виде:

$$y = \begin{cases} 1 & \text{при } \sum_{i=1}^N w_i u_i \geq v; \\ 0 & \text{при } \sum_{i=1}^N w_i u_i \leq v, \end{cases} \quad (5.1)$$

то есть:

$$y = f\left(\sum_{i=0}^N w_i u_i\right), \quad (5.2)$$

где

$$f(x) = \begin{cases} 1 & \text{при } x \geq 0 \\ 0 & \text{при } x < 0 \end{cases}.$$

Формула (5.2) описывает модель нейрона, представленную на рис. 5.4. В качестве функции  $f(x)$ , как правило, используется сигмоидальная функция, определяемая выражением

$$f(x) = \frac{1}{1 + e^{-\beta x}}.$$

На рис. 5.5 представлена многослойная нейронная сеть, состоящая из  $L$  слоев. В каждом слое расположено  $N_k$  элементов,  $k = 1, 2, \dots, L$ , обозначаемых  $AD_i^k$ ,  $i = 1, 2, \dots, N_k$ . Каждый из таких элементов представляет собой нейрон, структура которого аналогична нейрону, изображенному на рис. 5.4.

Рассматриваемая нейронная сеть имеет  $N_0$  входов, на которые подаются сигналы  $u_1(n), \dots, u_{N_0}(n)$ , записываемые в векторной форме

$$\mathbf{u} = [u_1(n), \dots, u_{N_0}(n)]^T, \quad n = 1, 2, \dots$$

Выходной сигнал  $i$ -го нейрона в  $k$ -м слое обозначается  $y_i^{(k)}(n)$ ,  $i = 1, \dots, N_k$ ,  $k = 1, \dots, L$ .

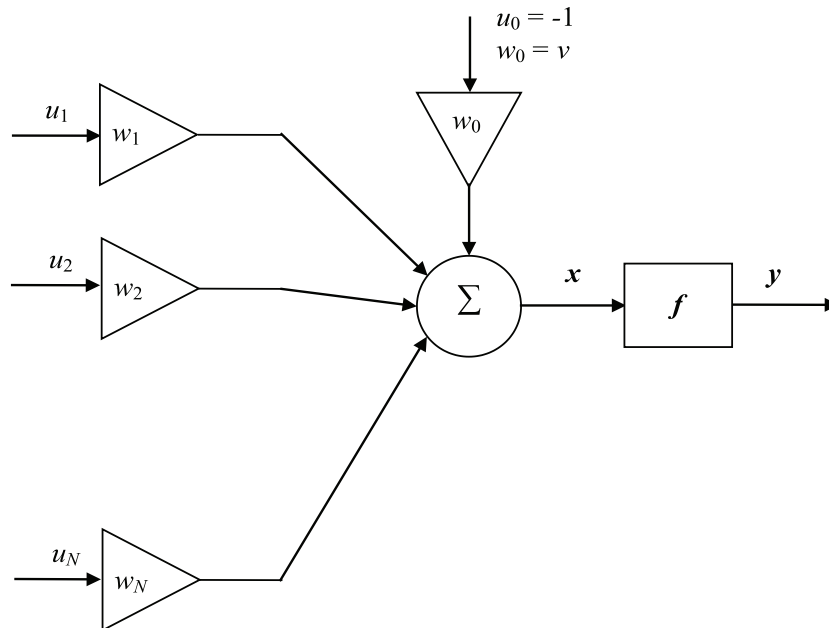


Рис. 5.4. Модель нейрона




Рис. 5.5. Многослойная нейронная сеть

Нейрон  $AD_i^k$  имеет  $N_k$  входов, образующих вектор

$$\mathbf{x}^{(k)}(n) = [x_0^{(k)}(n), \dots, x_{N_{k-1}}^{(k)}(n)]^T,$$

причем  $x_j^{(k)}(n) = +1$  для  $j = 0$  и  $k = 1, \dots, L$ .

Входной сигнал нейрона  $AD_i^k$  связан с выходным сигналом  $(k-1)$  слоя следующим образом:

$$x_j^k(n) = \begin{cases} u_i(n) & \text{для } k = 1, \\ y_j^{(k-1)} & \text{для } k = 2, \dots, L, \\ +1 & \text{для } j = 0, k = 1, \dots, L. \end{cases}$$

Обозначим  $w_{ij}^{(k)}(n)$  вес связи  $i$ -го нейрона,  $i = 1, \dots, N_k$ , расположенного в  $k$ -м слое, с  $j$ -м входным сигналом  $x_j^{(k)}(n)$ ,  $j = 0, 1, \dots, N_{k-1}$ . Вектор весов нейрона  $AD_i^k$  обозначим

$$\mathbf{w}_i^{(k)}(n) = [w_{i,0}^{(k)}(n), \dots, w_{i,N_{k-1}}^{(k)}(n)]^T, \quad k = 1, \dots, L, i = 1, \dots, N_k.$$

Выходной сигнал нейрона  $AD_i^k$  в  $n$ -й момент времени,  $n = 1, 2, \dots$  определяется как

$$y_i^{(k)}(n) = f(s_i^{(k)}(n)), \quad (5.3)$$

причем

$$s_i^{(k)}(n) = \sum_{j=0}^{N_{k-1}} w_{ij}^{(k)}(n) x_j^{(k)}(n). \quad (5.4)$$

Выходные сигналы нейронов в  $L$ -м слое

$$y_1^L(n), y_2^L(n), \dots, y_{N_L}^L(n) \quad (5.5)$$

одновременно являются выходными сигналами всей сети. Они сравниваются с так называемыми эталонными сигналами сети

$$d_1^L(n), d_2^L(n), \dots, d_{N_L}^L(n) \quad (5.6)$$

в результате чего получаем погрешность

$$\varepsilon_i^L(n) = d_i^L(n) - y_i^L(n), \dots, i = 1, \dots, N_L. \quad (5.7)$$

Сформулируем меру погрешности, основанную на сравнении сигналов (5.5) и (5.6), в виде суммы квадратов разностей (5.7):

$$Q(n) = \sum_{i=1}^{N_L} \left( \varepsilon_i^{(L)} \right)^2 (n) = \sum_{i=1}^{N_L} \left( d_i^L(n) - y_i^L(n) \right)^2. \quad (5.8)$$

Из выражений (5.3), (5.4) следует, что мера погрешности (5.8) является функцией весов сети. Обучение сети основано на адаптивной коррекции всех весов  $w_{ij}^{(k)}(n)$  таким образом, чтобы минимизировать меру погрешности. Для коррекции произвольного веса можно использовать правило наискорейшего спуска в следующем виде:

$$w_{ij}^{(k)}(n+1) = w_{ij}^{(k)}(n) - \eta \frac{\partial Q(n)}{\partial w_{ij}^{(k)}(n)}, \quad (5.9)$$

где константа  $\eta > 0$  определяет величину шага коррекции.

Вычислим производную в (5.9):

$$\frac{\partial Q(n)}{\partial w_{ij}^{(k)}(n)} = \frac{\partial Q(n)}{\partial s_i^{(k)}(n)} \frac{\partial s_i^{(k)}(n)}{\partial w_{ij}^{(k)}(n)} = \frac{\partial Q(n)}{\partial s_i^{(k)}(n)} x_j^{(k)}(n).$$

Если ввести обозначение

$$\delta_i^{(k)}(n) = -\frac{1}{2} \frac{\partial Q(n)}{\partial s_i^{(k)}(n)}, \quad (5.10)$$

то получим равенство

$$\frac{\partial Q(n)}{\partial w_{ij}^{(k)}(n)} = -2\delta_i^{(k)}(n) x_j^{(k)}(n).$$

При этом алгоритм (5.9) принимает вид

$$w_{ij}^{(k)}(n+1) = w_{ij}^{(k)}(n) + 2\eta \delta_i^{(k)}(n) x_j^{(k)}(n).$$

Способ расчета значения  $\delta_i^{(k)}(n)$ , заданного выражением (5.10), зависит от номера слоя. Для последнего слоя получаем

$$\begin{aligned} \delta_i^L(n) &= -\frac{1}{2} \frac{\partial Q(n)}{\partial s_i^L(n)} = -\frac{1}{2} \frac{\partial \sum_{m=1}^{N_L} \left( \varepsilon_m^L \right)^2 (n)}{\partial s_i^L(n)} = \\ &= -\frac{1}{2} \frac{\partial \left( \varepsilon_i^L \right)^2 (n)}{\partial s_i^L(n)} = -\frac{1}{2} \frac{\partial \left( d_i^L(n) - y_i^L(n) \right)^2}{\partial s_i^L(n)} = \\ &= \varepsilon_i^L(n) \frac{\partial y_i^L(n)}{\partial s_i^L(n)} = \varepsilon_i^L(n) f'(s_i^L(n)). \end{aligned}$$

Для произвольного слоя  $k \neq L$  получаем

$$\begin{aligned} \delta_i^{(k)}(n) &= -\frac{1}{2} \frac{\partial Q(n)}{\partial s_i^{(k)}(n)} = -\frac{1}{2} \sum_{m=1}^{N_{k+1}} \frac{\partial Q(n)}{\partial s_m^{(k+1)}(n)} \frac{\partial s_m^{(k+1)}(n)}{\partial s_i^{(k)}(n)} = \\ &= \sum_{m=1}^{N_{k+1}} \delta_m^{(k+1)}(n) w_{mi}^{k+1}(n) f'(s_i^{(k)}(n)) = \\ &= f'(s_i^{(k)}(n)) \sum_{m=1}^{N_{k+1}} \delta_m^{(k+1)}(n) w_{mi}^{k+1}(n). \end{aligned} \quad (5.11)$$

Определим погрешность в  $k$ -м (не последнем) слое для  $i$ -го нейрона в виде

$$\varepsilon_i^{(k)}(n) = \sum_{m=1}^{N_{k+1}} \delta_m^{(k+1)}(n) w_{mi}^{k+1}(n), \quad k = 1, \dots, (L-1). \quad (5.12)$$

Если подставить выражение (5.12) в (5.11), то получим

$$\delta_i^{(k)}(n) = \varepsilon_i^{(k)}(n) f'(s_i^{(k)}(n)).$$

В результате алгоритм обратного распространения ошибки можно записать в виде

$$y_i^{(k)}(n) = f(s_i^{(k)}(n)); \quad s_i^{(k)}(n) = \sum_{j=0}^{N_{k-1}} w_{ij}^{(k)}(n) x_j^{(k)}(n);$$

$$\varepsilon_i^{(k)}(n) = \begin{cases} d_i^L(n) - y_i^L(n) & \text{для } k=L; \\ \sum_{m=1}^{N_{k+1}} \delta_m^{k+1}(n) w_{mi}^{k+1}(n) & \text{для } k=1, 2, \dots, L; \end{cases}$$

$$\delta_i^k(n) = \varepsilon_i^{(k)}(n) f'(s_i^{(k)}(n));$$

$$w_{ij}^{(k)}(n+1) = w_{ij}^{(k)}(n) + 2\eta \delta_i^{(k)}(n) x_j^{(k)}(n).$$

Идея алгоритма связана со способом расчета погрешностей в конкретных слоях. В первую очередь рассчитываются погрешности в последнем слое (на основе выходных и эталонных сигналов), далее — в предпоследнем и так до первого слоя. Начальные значения весов выбираются случайными и, как правило, устанавливаются близкими к нулю.

### 5.3. Нейронные сети и их применение в задачах распознавания РЛИ

Из предыдущих разделов следует вывод, что одним из перспективных инструментов решения задачи классификации РЛИ являются нейронные сети [1, 2], основой которых может служить многослойный персептрон (рис. 5.6.). Применение названного инструмента проблематично из-за того, что РЛИ имеют большую размерность и требуется большой объём тренировочной выборки.




Рис. 5.6. Многослойный персептрон

#### Персептрон

Для обучения персептрона обычно предъявляется последовательность РЛИ, в которую входят представители каждого из классов, подлежащих различению. Правильный выбор запоминается. После предъявления контрольных РЛИ определяется вероятность правильного решения для каждого класса.

### Многослойные нейронные сети

Архитектура многослойной нейронной сети (МНС) состоит из последовательно соединённых слоёв, где нейрон каждого слоя своими входами связан со всеми нейронами предыдущего слоя, а выходами — следующего. Нейронная сеть с двумя решающими слоями может с любой точностью аппроксимировать любую многомерную функцию. Обучаются МНС при помощи алгоритма обратного распространения ошибки, являющегося методом градиентного спуска в пространстве весов с целью минимизации суммарной ошибки сети. При этом ошибки (точнее величины коррекции весов) распространяются в обратном направлении от выходов к входам, сквозь веса, соединяющие нейроны.

МНС так же используется для непосредственной классификации РЛИ — на вход подаётся или само изображение в каком-либо виде, или набор ранее извлечённых ключевых характеристик изображения, на выходе нейрон с максимальной активностью указывает принадлежность к распознанному классу (рис. 5.7).

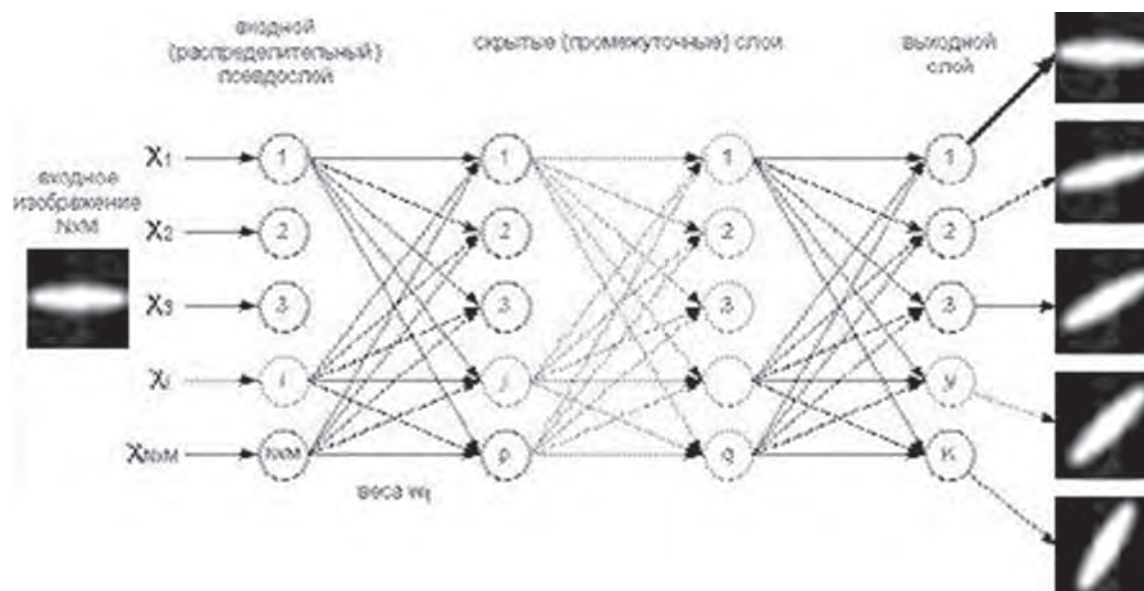


Рис. 5.7. Многослойная нейронная сеть для классификации изображений

В классической МНС межслойные нейронные соединения полносвязны, и изображение представлено в виде одномерного вектора, хотя оно двумерно. Архитектура свёрточной НС направлена на преодоление этих недостатков. В ней использовались локальные рецепторные поля, общие веса и иерархическая организация с пространственными подвыборками.

### Свёрточная нейронная сеть

Свёрточная НС (СНС) обеспечивает частичную устойчивость к изменениям масштаба, смещениям, поворотам, искажениям. Архитектура СНС состоит из многих слоёв, каждый из которых имеет несколько плоскостей, причём нейроны следующего слоя связаны только с небольшим числом нейронов предыдущего слоя из окрестности локальной области (как в зрительной коре человека). Веса в каждой точке одной плоскости одинаковы (свёрточные слои). За свёрточным слоем следует слой, уменьшающий его размерность путём локального усреднения. Затем опять реализуется свёрточный слой, и так далее. Таким образом, достигается



иерархическая организация. Более поздние слои извлекают более общие характеристики, меньше зависящие от искажений изображения. Обучается СНС стандартным методом обратного распространения ошибки.

Сверточная нейронная сеть представляет собой особый класс НС, наилучшим образом подходящий для интеллектуальной обработки визуальных данных. Идея сверточных нейронных сетей заключается в чередовании сверточных слоев (C-layers), субдискретизирующих слоев (S-layers) и наличия полносвязных (F-layers) слоев на выходе. Они объединяют в себе три архитектурных идеи для достижения инвариантности к сдвигу и искажению исходных РЛИ.

Концепция разделяемых весов предполагает, что для большого количества связей используется очень небольшой набор весов.

Типичная структура сверточной нейронной сети представлена на рис. 5.8.

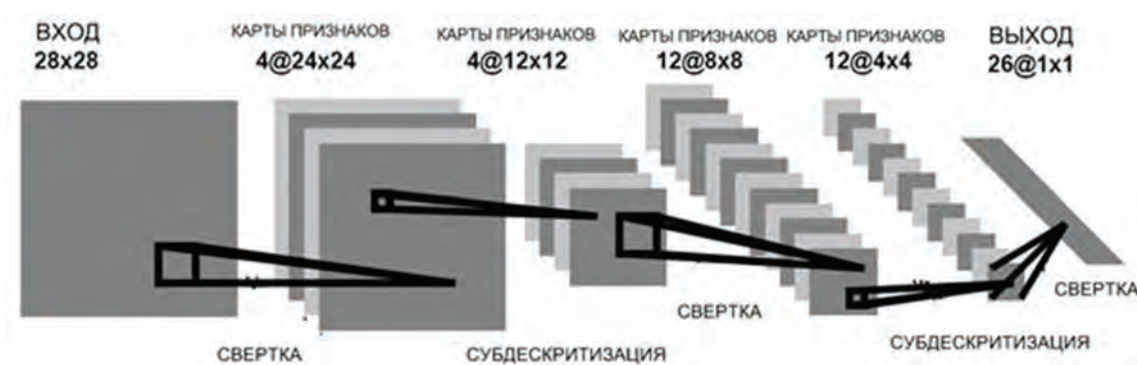


Рис. 5.8. Сверточная нейронная сеть

#### Нейронные сети высокого порядка

Нейронные сети высокого порядка (НСВП) отличаются от МНС тем, что у них только один слой, но на входы нейронов поступают термы высокого порядка, являющиеся произведением двух или более компонент входного вектора. Такие сети так же могут формировать сложные разделяющие поверхности. Особенность такой сети заключается в том, что для обучения некоторому классу достаточно предъявить его образ без вариаций масштабов и поворотов — после обучения сеть будет распознавать известные классы инвариантно к масштабу и поворотам.

#### Нейронные сети Хопфилда

НС Хопфилда (НСХ) является однослойной и полносвязной (связи нейронов на самих себя отсутствуют): её выходы связаны со входами. В отличие от МНС, НСХ является релаксационной — то есть, будучи установленной в начальное состояние, функционирует до тех пор, пока не достигнет стабильного состояния, которое и будет являться её выходным значением. НСХ применяются в качестве ассоциативной памяти и для решения оптимизационных задач. В первом случае НСХ обучается без учителя (например, по правилу Хебба), во втором случае веса между нейронами изначально кодируют решаемую задачу. НСХ бывают синхронными, когда одновременно пересчитываются все нейроны и асинхронными, когда пересчитывается случайно выбранный нейрон. Для исследования динамики функционирования НСХ используются методы Ляпунова. Показано, что асинхронная НСХ всегда сходится к устойчивым точкам, а аттракторами синхронной НСХ являются устойчивые стационарные точки и предельные циклы длины два.

Применение НСХ в качестве ассоциативной памяти позволяет точно восстанавливать РЛИ, которым сеть обучена, при подаче на вход искажённого образа. При этом сеть «вспомнит» наиболее близкий (в смысле локального минимума энергии) образ, и таким образом распознает его.

#### Самоорганизующиеся нейронные сети Кохонена

Самоорганизующиеся нейронные сети Кохонена (НСК) обеспечивают топологическое упорядочивание входного пространства образов. Они позволяют топологически непрерывно отображать входное  $n$ -мерное пространство в выходное  $m$ -мерное. Такое преобразование обеспечило частичную устойчивость к изменению освещения, смещениям и искажениям, избавило от необходимости предварительной обработки изображения (преимущество — ускорение работы), а так же значительно ускорило процесс обучения и классификации, делая эту систему применимой в реальном времени (использовалась для распознавания лиц). Отмечено так же небольшое преимущество СКК перед методом анализа главных компонент, которое заключалось в более высокой точности последующей классификации на основе данных уменьшенной размерности.

#### Нейронная сеть с радиально-базисной функцией

Нейронная сеть с радиально-базисной функцией (НСРБФ) является дальнейшим развитием НС Кохонена, в которой после конкурентного слоя добавлен ещё один слой, обучаемый по методу обратного распространения. В отличие от НС Кохонена в НСРБФ выходами нейронов конкурентного слоя являются значения функции Гаусса с нормальным законом распределения, и обнуление «проигравших» нейронов не требуется. Ширина радиально-базисной функции характеризует расстояние между центром кластера, который образуется каждым нейронным элементом и его ближайшими соседями.

#### Когнитрон

Когнитрон своей архитектурой похож на строение зрительной коры, имеет иерархическую многослойную организацию, в которой нейроны между слоями связаны только локально. Сеть обучается с помощью конкурентного обучения (без учителя). Каждый слой реализует различные уровни обобщения; входной слой чувствителен к простым образам, таким, как линии, и их ориентации в определенных областях визуальной области, в то время как реакция других слоев является более сложной, абстрактной и независимой от позиции образа.

#### Неокогнитрон

Неокогнитрон более точно отражает строение зрительной системы, позволяет распознавать образы независимо от их преобразований, вращений, искажений и изменений масштаба. Неокогнитрон может как самообучаться, так и обучаться с учителем. Неокогнитрон получает на входе двумерные образы, аналогичные изображениям на сетчатой оболочке глаза, и обрабатывает их в последующих слоях аналогично тому, как это было обнаружено в зрительной коре человека. Конечно, в неокогнитроне нет ничего, ограничивающего его использование только для обработки визуальных данных, он достаточно универсален и может найти широкое применение как обобщенная система распознавания образов.

В зрительной коре были обнаружены узлы, реагирующие на такие элементы, как линии и углы определенной ориентации. На более высоких уровнях узлы реагируют на более сложные и абстрактные образы такие, как окружности, треугольники

и прямоугольники. На еще более высоких уровнях степень абстракции возрастает до тех пор, пока не определяются узлы, реагирующие на образ ПРЦ и сложные формы. В общем случае узлы на более высоких уровнях получают вход от группы низкоуровневых узлов и, следовательно, реагируют на более широкую область визуального поля. Реакции узлов более высокого уровня менее зависят от позиции и более устойчивы к искажениям.

Когнитрон является мощным средством распознавания изображений, однако требует высоких вычислительных затрат, которые на сегодняшний день недостижимы.

#### Вероятностная нейронная сеть

В задачах классификации выходы сети можно интерпретировать как оценки вероятностей того, что элемент принадлежит некоторому классу, и сеть фактически учится оценивать функцию плотности вероятности. Аналогичная полезная интерпретация может иметь место и в задачах регрессии — выход сети рассматривается как ожидаемое значение модели в данной точке пространства входов. Это ожидаемое значение связано с плотностью вероятности совместного распределения входных и выходных данных.

При решении задачи классификации можно оценить плотность вероятности для каждого класса, сравнить между собой вероятности принадлежности различным классам и выбрать наиболее вероятный. Другой подход к оценке плотности вероятности основан на ядерных оценках. Тот факт, что наблюдение расположено в данной точке пространства, свидетельствует о том, что в этой точке имеется некоторая плотность вероятности. Кластеры из близко лежащих точек указывают на то, что в этом месте плотность вероятности большая. Вблизи наблюдения имеется большее доверие к уровню плотности, а по мере отдаления от него доверие убывает и стремится к нулю (рис. 5.9).

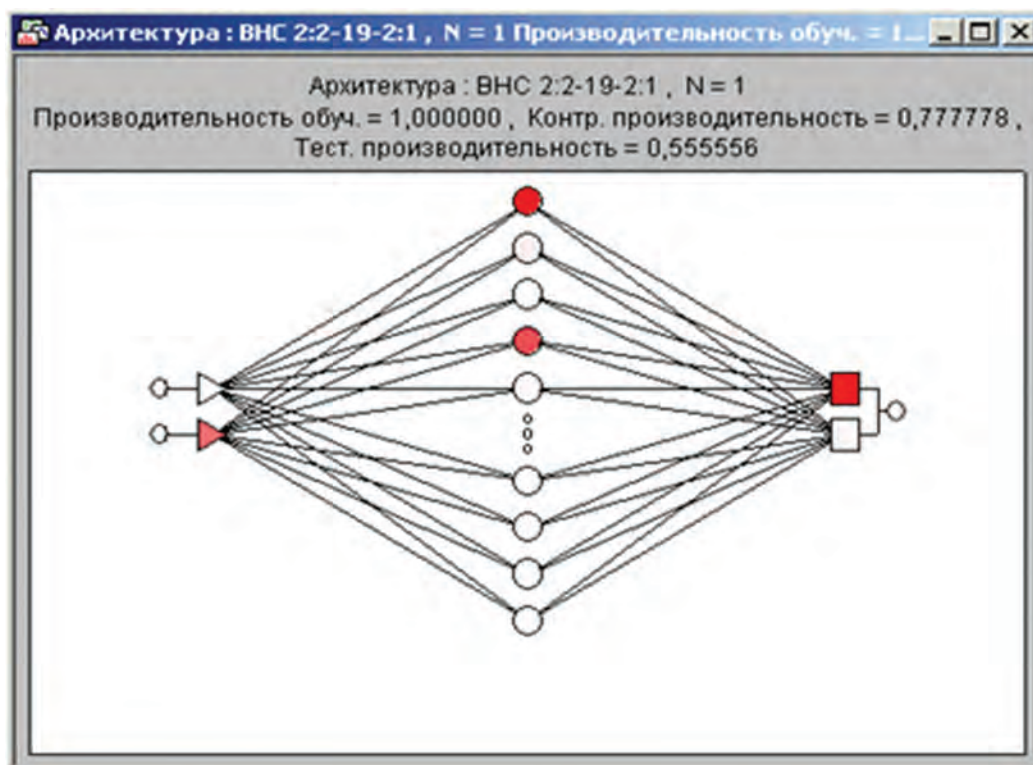


Рис. 5.9. Вероятностная нейронная сеть

### Сравнительный анализ нейронных сетей применительно к задаче классификации ПРЦ

Далее приведём результаты исследования процедуры классификации РЛИ нейронными сетями различной структуры [2, 3]: многослойный персептрон, радиальная базисная функция, вероятностная нейронная сеть, обобщенная регрессионная нейронная сеть, самоорганизующаяся карта Кохонена, линейная сеть, сеть главных компонент.

Выбор архитектуры построения сети аналитическими и/или расчётными методами до её реального использования в конкретной практической задаче является весьма проблематичным.

Именно поэтому задача выбора решается на модели, по возможности адекватной по содержанию конкретной практической проблеме классификации. Проиллюстрируем высказанные соображения на модели классификации трёх типов ПРЦ, отличающихся своими размерами и конфигурацией.

Для создания обучающей выборки был использован пакет MS Office. Было создано 12 картинок 7×7 (рис. 5.10), отображающих изображения трех разных классов ПРЦ (большая, средняя и малая).

*Большая (A1)*

|    |    |    |    |    |    |    |
|----|----|----|----|----|----|----|
| 1  | 2  | 3  | 4  | 5  | 6  | 7  |
| 8  | 9  | 10 | 11 | 12 | 13 | 14 |
| 15 | 16 | 17 | 18 | 19 | 20 | 21 |
| 22 | 23 | 24 | 25 | 26 | 27 | 28 |
| 29 | 30 | 31 | 32 | 33 | 34 | 35 |
| 36 | 37 | 38 | 39 | 40 | 41 | 42 |
| 43 | 44 | 45 | 46 | 47 | 48 | 49 |

*Средняя (B1)*

|    |    |    |    |    |    |    |
|----|----|----|----|----|----|----|
| 1  | 2  | 3  | 4  | 5  | 6  | 7  |
| 8  | 9  | 10 | 11 | 12 | 13 | 14 |
| 15 | 16 | 17 | 18 | 19 | 20 | 21 |
| 22 | 23 | 24 | 25 | 26 | 27 | 28 |
| 29 | 30 | 31 | 32 | 33 | 34 | 35 |
| 36 | 37 | 38 | 39 | 40 | 41 | 42 |
| 43 | 44 | 45 | 46 | 47 | 48 | 49 |

*Малая (B1)*

|    |    |    |    |    |    |    |
|----|----|----|----|----|----|----|
| 1  | 2  | 3  | 4  | 5  | 6  | 7  |
| 8  | 9  | 10 | 11 | 12 | 13 | 14 |
| 15 | 16 | 17 | 18 | 19 | 20 | 21 |
| 22 | 23 | 24 | 25 | 26 | 27 | 28 |
| 29 | 30 | 31 | 32 | 33 | 34 | 35 |
| 36 | 37 | 38 | 39 | 40 | 41 | 42 |
| 43 | 44 | 45 | 46 | 47 | 48 | 49 |

Рис. 5.10. Классифицируемые изображения


Оставшиеся картинки повторяют приведённые РЛИ, но повернуты на 45 градусов по часовой стрелке.

В результате классификации подвергаются 12 образов входных сигналов (A1, A2, A3, A4, B1, B2, B3, B4, V1, V2, V3, V4), каждый из которых состоит из 49 переменных.

Для обучения нейронной сети были созданы последовательности обучающих изображений (по 100 для каждого класса с нормальным распределением отдельных отсчётов. Математическое ожидание фона = 0, стандартное отклонение фона = 0,1. Математическое ожидание отсчёта изображения, отвечающего за элемент ПРЦ равен 1, стандартное отклонение = 0,1; 0,2; 0,3).

### Многослойный персептрон кросс энтропия

#### 1 слой




Ср. откл. 0,1 ошибка 0,00

Ср. откл. 0,2 ошибка 0,03

Ср. откл. 0,3 ошибка 0,17

#### 2 слоя




Ср. откл. 0,1 ошибка 0,00

Ср. откл. 0,2 ошибка 0,08

Ср. откл. 0,3 ошибка 0,34

#### 3 слоя



Ср. откл. 0,1 ошибка 0,0125

Ср. откл. 0,2 ошибка 0,25

Ср. откл. 0,3 ошибка 0,53

Рис. 5.11. Результаты моделирования НС



Результаты моделирования представлены в виде условных рисунков (рис. 5.8–5.11), наглядно демонстрирующих качество работы сети. Каждая «ступенька» на графиках означает номер класса. В случае безошибочной классификации (принятии правильного решения) ступенька остаётся плоской. Наличие ошибки демонстрируется скачком с той позиции, которая соответствует верному решению, на ступеньку, которая соответствует принятому решению. При этом качество сети тем хуже, чем больше таких скачков (чем более густое изображение)<sup>24</sup>.

В результате исследований были выявлены две нейронные сети наиболее пригодные для решения задачи классификации: вероятностная нейронная сеть и линейная сеть.

#### 5.4. Оценка ракурса (ориентации) ПРЦ с помощью нейронных сетей

Для обучения НС были сформированы 12 моделей различной конфигурации. Для получения обучающей выборки на каждую модель были наложены шумы (10 %) от яркости. В результате была создана обучающая выборка в 1200 изображений 12 различных классов (рис. 5.12, 5.13).




Рис. 5.12. Примеры РЛИ




Рис. 5.13. Форма загрузки моделей для обучения

<sup>24</sup> Анализ многослойного персептрона (рис. 5.11) для классификации заданных изображений позволяет сделать вывод о том, что наличие дополнительных слоёв ухудшает качество классификации (число ошибочных решений — скачков на изображении заметно возрастает).

После обучения нейронной сети НС предъявляются «рабочие РЛИ» и «обученная» нейронная сеть определяет меру «схожести» входного изображения с тем или иным классом (рис. 5.14).

Рис. 5.14. Форма проверки результатов обучения НС

Результаты показаны на рис. 5.15, а, б, в.




Рис. 5.15а. Среднее отклонение 10%. ошибка 0,015




Рис. 5.15б. Отклонение 20 % ошибка 0,31




Рис. 5.15в. 30 %, 0,64

## 5.5. Классификация ПРЦ по интенсивности

Для постановки эксперимента были созданы 3 шаблона, представляющие ПРЦ с одинаковыми ракурсами, размерами и интегральной интенсивностью отражений, но различными распределениями интенсивности отражения по площади ПРЦ: «яркий слева», «яркий центр», «яркий справа» рис. 5.16).



Рис. 5.16. Модели изображений ПРЦ

Для обучения нейронной сети на вход подается 3 РЛИ (по 10 каждого варианта распределения интенсивности).

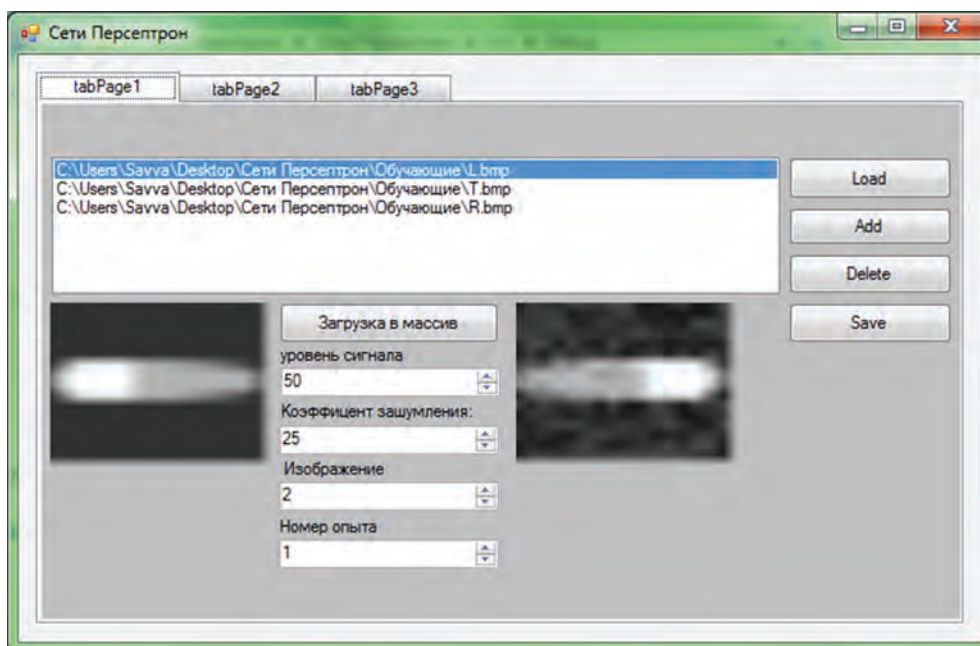


Рис. 5.17. Рабочее окно программы моделирования

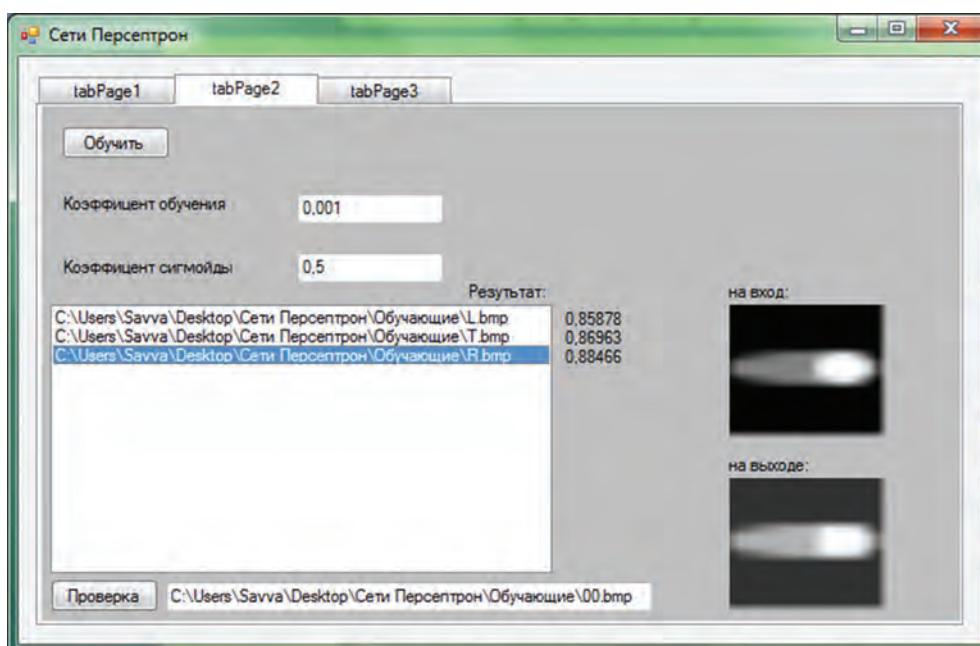


Рис. 5.18. Рабочее окно программы моделирования

При последовательном предъявлении обученной сети изображений моделей ПРЦ с различной интенсивностью (3 различных шаблона по 30 каждого типа) был получен график отклика нейронной сети могут быть получены количественные результаты для оценки вероятностей правильной и ошибочной классификаций. Соответствующие результаты приведены на рис. 5.19 и 5.20.

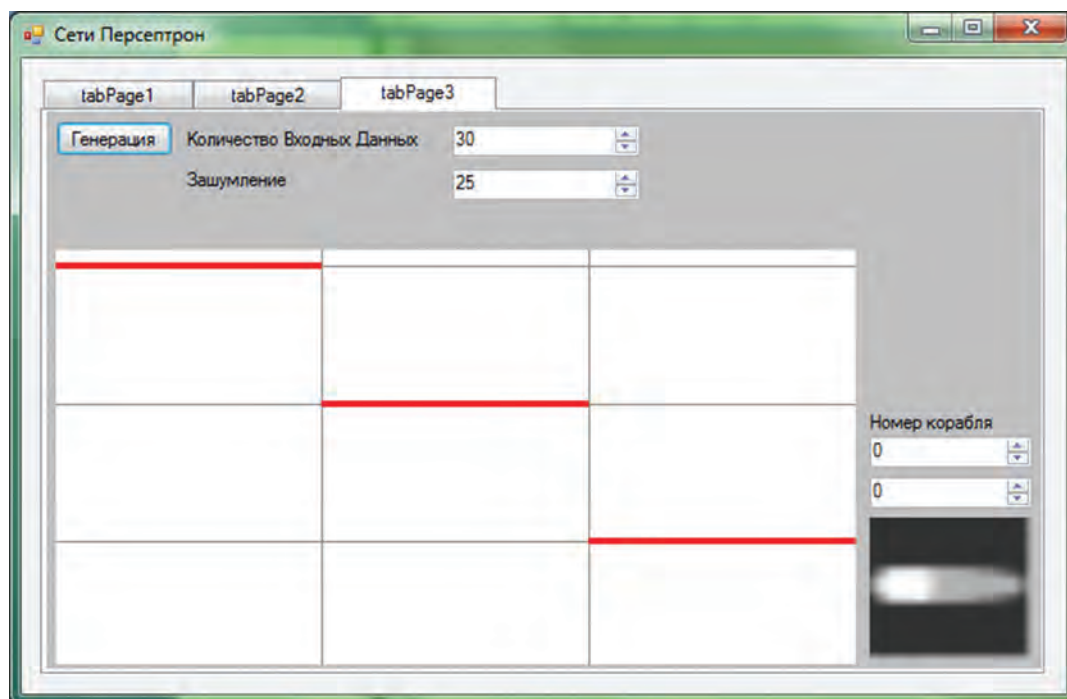


Рис. 5.19. Результаты работы нейронной сети при 10 % зашумленности предъявляемых изображений

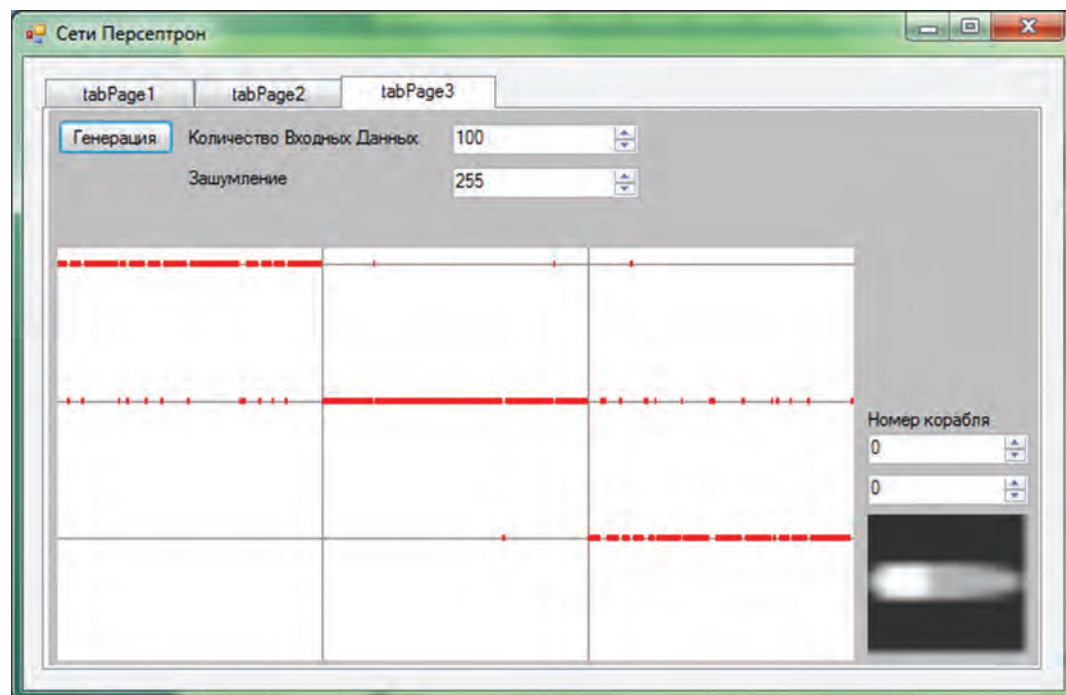


Рис. 5.20. Результаты работы нейронной сети при 100 % зашумленности предъявляемых изображений



## 5.6. Литература к главе 5

1. Барский А.Б. Нейронные сети: распознавание, управление, принятие решений / А.Б. Барский. — М.: Финансы и статистика, 2004. — 176 с.  
Тархов Д.А. Нейронные сети. Модели и алгоритмы / Д.А. Тархов — М.: Радиотехника, 2005. — 256 с.
3. Хайкин С. Нейронные сети / С. Хайкин. — М.: Издательский дом «Вильямс», 2006. — 1103 с.
4. Рутковская Д., Пилиньский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечёткие множества. Пер. с польского И.Д. Рудинского. — Горячая линия — Телеком, 2006. 452 с.
5. Доросинский Л.Г. Основы теории принятия решений / Л.Г. Доросинский. — Екатеринбург: УрФУ. 2012. — 111 с.
6. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА. Издательский дом Академии естествознания. 2018.

## 6. ОБНАРУЖЕНИЕ СИГНАЛОВ В ЧАСТИЧНО-КОГЕРЕНТНЫХ РСА

### 6.1. Постановка задачи

В большом числе практических ситуаций когерентное суммирование отраженных от цели импульсов в течение всего времени искусственного синтезирования апертуры антенны невозможно, вследствие фазовых флуктуаций отраженного сигнала, вызванных нестабильностью генератора, случайными отклонениями траектории летательного аппарата, случайными флуктуациями отраженных сигналов и т. п. В этом случае время когерентного накопления может оказаться значительно меньше общего времени формирования радиолокационного изображения (РЛИ), и когерентная обработка в течение всего времени приема сигнала перестает быть оптимальной и эффективность обнаружения существенно ухудшается по сравнению с частично-когерентной РСА, осуществляющей когерентное накопление в течение времени когерентности с последующим некогерентным суммированием полученных РЛИ [1]. Кроме того, такая обработка позволяет снизить искажающее влияние спекл-эффекта. И, наконец, использование частично-когерентной обработки позволяет использовать оптимальные и близкие к ним методы пространственно-временной обработки, позволяющие, по крайней мере, в принципе повысить помехозащищенность РСА по отношению к активным и пассивным помехам. Поскольку, как правило, некогерентному суммированию подвергается относительно небольшое количество отсчетов, предположение о гауссовском характере решающей статистики далеко не всегда является обоснованным, и анализ эффективности алгоритма обнаружения представляет собой достаточно сложную задачу, которая может быть решена путем аппроксимации распределения решающей статистики различными методами, из которых, по нашему мнению, наиболее целесообразным является применение смешанного семейства кривых Джонсона и Пирсона [2].

Далее предполагаем, что сигналы, отраженные от разных каналов дальности, статистически независимы. Применительно к РСА с боковым обзором необходимые геометрические соотношения для одного канала дальности поясняются на рис. 6.1.

Рассмотрим ситуацию, когда длина всего искусственного раскрытия  $L_{\text{общ}}$  разделена на несколько подапертур длиной  $L$ . Число таких подапертур определяется количеством некогерентных накоплений  $N_{\text{НКГ}}$ . Внутри каждой подапертуры обработка осуществляется когерентно, причем число когерентных накоплений равно  $N_{\text{КГ}}$ . Расстояние между точкой поверхности с координатой  $x$  и  $k$ -й точкой приема ( $k = 1, N_{\text{НКГ}}$ ) в  $n$ -й подапертуре ( $n = 1, N_{\text{НКГ}}$ ) можно записать в следующем виде:

$$\begin{aligned} R_{kn} &= \sqrt{R_H^2 + \{[n-1-0,5N_{\text{НКГ}}]L + k\Delta r - x\}^2} \simeq \\ &\simeq R_H + \frac{\{[n-1-0,5N_{\text{НКГ}}]L + k\Delta r\}^2}{2R_H} - \frac{\{[n-1-0,5N_{\text{НКГ}}]L + \Delta r\}x}{R_H}, \end{aligned} \quad (6.1)$$

где  $R_H$  — наклонная дальность до центра цели,  $\Delta r = vT$  — расстояние вдоль траектории между точками приема соседних отраженных импульсов ( $v$  — скорость цели  $T$  — период повторения зондирующих импульсов).

Пусть цель распределена по азимуту и ее отдельные элементы имеют координаты  $x_{cm}$  ( $m = 1, N$ , где  $N$  — число элементов цели). Наблюдения производятся на фоне

подстилающей поверхности, элементы которой задаются координатами  $x_{\phi i}$  ( $i = \overline{1, N_{\phi}}$ ), где  $N_{\phi}$  – число элементов фона, «укладывающихся» в пределах участка поверхности, «освещаемого» реальной диаграммой направленности. Кроме того, считаем, что обнаружение производится в присутствии белого гауссовского шума.




Рис. 6.1. К выводу алгоритма обнаружения пространственно-распределённой цели в частично-когерентной РСА

При этих условиях комплексная амплитуда наблюдаемых данных в  $k$ -й точке  $n$ -й подапертуры имеет вид:

$$U_{nA}^k = \sum_{m=1}^N g^2 [\beta(n, k) - x_{cm}] f_{cm_n}^k \exp \left\{ j \frac{4\pi}{\lambda R_H} [0, 5\beta^2(n, k) - x_{cm}\beta(n, k)] \right\} + \sum_{m=1}^{N_{\phi}} g_A^2 [\beta(n, k) - x_{\phi m}] f_{\phi m_n}^k \exp \left\{ j \frac{4\pi}{\lambda R_H} [0, 5\beta^2(n, k) - x_{\phi m}\beta(n, k)] \right\} + f_{\text{ш}}^k, \quad (6.2)$$

где  $f_c, f_{\phi}, f_{\text{ш}}$  – комплексные амплитуды сигнала, фона и шума;  $g_A[\cdot]$  – диаграмма направленности по азимуту,

$$\beta(n, k) = (n - 1 - 0, 5N_{\text{НКТ}})L + k\Delta r.$$

Алгоритм обработки, близкий к оптимальному, должен выполнять следующие операции:

а) демодуляция сигнала с линейной частотной модуляцией и когерентное суммирование в пределах подапертуры;

б) некогерентное суммирование сигналов различных апертур.

При выполнении названных операций решающая статистика для обнаружения в  $\alpha$ -м канале дальности может быть записана следующим образом:

$$z_d = \sum_{n=1}^{N_{\text{НКТ}}} \left| \sum_{k=1}^{N_{\text{КГ}}} U_n^{K^d} \exp \left[ -j \frac{2\pi}{\lambda R_H} \beta^2(n, k) \right] \right|^2 = \sum_{n=1}^{N_{\text{НКТ}}} |z_n^d|^2. \quad (6.3)$$

Поскольку наблюдаемые данные в различных каналах дальности статистически независимы (по крайней мере, такая ситуация является наиболее распространенной), результирующая статистика формируется путем суммирования отсчетов различных каналов дальности:

$$z_D = \sum_{d=1}^{N_D} z_d, \quad (6.4)$$

где  $d=1, \overline{N_D}$  ( $N_D$  — число каналов дальности).

Для принятия решения об обнаружении цели статистика (6.4) сравнивается с порогом, установленным исходя из заданной вероятности ложной тревоги.

## 6.2. Анализ эффективности обнаружения

Для анализа эффективности обнаружения при частично-когерентной обработке необходимо рассчитать характеристики обнаружения. Расчет названных характеристик требует знания плотностей вероятностей статистики (6.4) при наличии и отсутствии цели. Этот расчет представляет собой достаточно сложную задачу в связи с очевидной негауссовостью распределения решающей статистики и производится, как правило, приближенными методами, основанными на аппроксимации распределения решающей статистики. Причем, как показано в [1], наиболее удачными аппроксимирующими функциями являются функции из семейства распределений Джонсона и Пирсона. Для использования названной аппроксимации необходимо знание четырех моментов распределения статистики (4), после чего расчет характеристик производится по хорошо отлаженной стандартной методике [3]. Для отыскания требуемых моментов, найдём корреляционную матрицу вектора  $Z_d = (Z_1, Z_2, \dots, Z_n, \dots, Z_{N_{\text{НКТ}}})^T$ :

$$\begin{aligned} \Phi_d &= \frac{1}{2} M \{ z_d z_d^{*T} \} = \|\Phi_{n_1}^d\| = \\ &= \left\| \sum_{k_1=1}^{N_{\text{КГ}}} \sum_{k_2=1}^{N_{\text{КГ}}} \left\{ \sum_{m=1}^{N_d} \sigma_{cm}^{2^d} g_A^2 [\beta(n, k_1) - x_{cm}^d] g_A^2 [\beta(1, k_2) - x_{cm}^d] \cdot P_{cm} [\beta(n, k_1) - \beta(1, k_2)] \times \right. \right. \\ &\times \exp \left\{ -j \frac{4\pi}{\lambda R_H} x_{cm}^d [\beta(n, k_1) - \beta(1, k_2)] + \sum_{i=1}^{N_\Phi} \sigma_{\Phi_i}^{2^d} g_A^2 [\beta(n, k_1) - x_{\Phi_i}^d] g_A^2 [\beta(1, k_2) - x_{\Phi_i}^d] \times \right. \\ &\times P_{\Phi_i} [\beta(n, k_1) - \beta(1, k_2)] \exp \left\{ -j \frac{4\pi}{\lambda R_H} x_{\Phi_i}^d [\beta(n, k_1) - \beta(1, k_2)] + \delta_{\text{ш}}^2 \delta_{n_1} \delta_{k_1 k_2} \right\} \Bigg\} \Bigg\|, \end{aligned} \quad (6.5)$$

где  $\sigma_{cm}^{2^d}$ ,  $\sigma_{\Phi_i}^{2^d}$ ,  $\sigma_{\text{ш}}^2$  — мощности сигналов в точке приема от  $m$ -го элемента цели, и  $i$ -го элемента фона и мощности шума;  $P_{cm}(\cdot)$ ,  $P_{\Phi_i}(\cdot)$  — коэффициенты корреляции

сигнала  $m$ -го элемента цели и 1-го элемента фона;  $M\{\cdot\}$  – операция вычисления математического ожидания;  $\delta_{ij}$  – символ Кронеккера;  $^{*T}$  – знаки комплексного сопряжения и транспонирования.

Полученное выражение определяет корреляционную матрицу для одного канала деятельности. Введем матрицу  $Z = (Z_1, Z_2, \dots, Z_d, \dots, Z_{N_D})^T$ , где, в свою очередь, каждый вектор имеет вид:  $Z_d = (Z_d^1, \dots, Z_d^{N_{\text{НКГ}}})$  и запишем корреляционную матрицу для вектора  $Z$  в виде блочной матрицы:

$$\Phi = \begin{bmatrix} \Phi_1 & & & \\ & \Phi_2 & & \\ & & \ddots & \\ & & & \Phi_{N_D} \end{bmatrix}, \quad (6.6)$$

где каждый блок  $\Phi_d$  находится из выражения (6.5).

После определения корреляционной матрицы (6.6) расчет моментов распределения статистики  $Z_D$  производится аналогично задачи отыскания моментов оценки дисперсии гауссовских стационарных последовательностей. Первые четыре начальных момента  $\alpha_1, 1=\overline{1,4}$  распределения статистики  $Z_D$  могут быть представлены в следующем виде:

$$\begin{aligned} \alpha_1 &= S_{p\Phi}; \quad \alpha_2 = 2S_{p\Phi} + (S_{p\Phi})^2; \\ \alpha_3 &= 8S_{p\Phi}^2 + 6S_{p\Phi}S_{p\Phi}^2 + (S_{p\Phi})^3; \\ \alpha_4 &= 48S_{p\Phi}^4 + 32S_{p\Phi}^3S_{p\Phi} + 12(S_{p\Phi}^2)^2 + 12S_{p\Phi}^2(S_{p\Phi})^2 + (S_{p\Phi})^4, \end{aligned} \quad (6.7)$$

где  $S_{p\Phi}$  – след матрицы  $\Phi$ . Для определения следа степени матрицы справедливо равенство:  $S_{p\Phi}^K = \sum_{i=1}^{N_{\text{НКГ}}} \lambda_i^K$ , где  $\lambda_i$  –  $i$ -е собственное значение матрицы  $\Phi$ .

Для использования методики, основанной на аппроксимации распределений функциями Джонсона и Пирсона, следует определить центральные моменты, а именно: математическое ожидание  $\mu_1 = \alpha_1$ , дисперсию  $\mu_2 = \alpha_2 - \alpha_1^2$ , третий центральный момент  $\mu_3 = \alpha_3 - 3\alpha_1\alpha_2 + 2\alpha_1^3$  и четвертый центральный момент  $\mu_4 = \alpha_4 - 4\alpha_1\alpha_3 + 6\alpha_1^2\alpha_2 - 3\alpha_1^4$ .

Подставив в данные соотношения выражения начальных моментов, получаем:

$$\mu_1 = S_{p\Phi}; \quad \mu_2 = 2S_{p\Phi}^2; \quad \mu_3 = 8S_{p\Phi}^3; \quad \mu_4 = 48S_{p\Phi}^4 + 12(S_{p\Phi}^2)^2.$$

Необходимо отметить, что при вычислении статистики  $Z_D$ , как правило, реализуется квадратурная обработка, т.е. вместо комплексной матрицы  $\Phi$  используется действительная матрица размерности  $2N_{\text{НКГ}} \times 2N_{\text{НКГ}}$ :

$$W = \begin{bmatrix} \text{Re } \Phi & -\text{Im } \Phi \\ \text{Im } \Phi & \text{Re } \Phi \end{bmatrix}. \quad (6.8)$$

После определения моментов могут быть найдены аппроксимирующие распределения, интегрирование которых позволяет найти вероятность ложной тревоги и правильного обнаружения.



Конкретный пример расчета характеристик обнаружения распределенных целей был выполнен при следующих предположениях:

1. Фон отсутствует.
2. Обнаруживаемая цель расположена в одном канале дальности.
3. Нормированная диаграмма направленности реальной антенны постоянна в пределах ее ширины по уровню половинной мощности.
4. В качестве моделей выбирались:
  - а) точечная цель;
  - б) цель, состоящая из пяти элементарных отражателей, равномерно распределенных в пределах участка поверхности, занимающего 0,25 от потенциальной разрешающей способности;
  - в) цель, состоящая из десяти элементарных отражателей, равномерно распределенных в пределах участка поверхности, занимающего 0,5 от потенциальной разрешающей способности;
  - г) цель из двадцать отражателей, равномерно распределенных в пределах всего участка поверхности, равного потенциальной разрешающей способности (т. е. разрешающей способности, рассчитанной из условия, что в течение времени наблюдения осуществляется чисто когерентная обработка).

Последнее предположение означает, что цель состоит из элементарных отражателей, размер каждого из которых, по крайней мере в 20 раз меньше потенциальной разрешающей способности РСА. А это, в свою очередь, означает, что коэффициент корреляции вдоль синтезируемой апертуры можно считать приблизительно постоянным  $\rho = 1$ . При названных условиях корреляционная матрица, необходимая для расчета характеристик обнаружения, принимает вид:

$$\Phi = \Phi_{n_1} = \sum_{k_1=1}^{N_{\text{кг}}} \sum_{k_2=1}^{N_{\text{кг}}} \left\{ \sum_{m=1}^N x_{cm} \exp \left\{ -\frac{4\pi}{\lambda R_H} x_{cm} [\beta(n_1, k_1) - \beta(n_2, k_2)] \right\} \right\} + \delta_{m_1}, \quad (6.9)$$

где  $x_{cm} = \frac{\sigma_{cm}^2}{\sigma_{\text{ш}}^2}$  — отношение сигнал/шум для  $m$ -го элементарного отражателя.

Характеристики обнаружения для названных выше четырех типов целей приведены на рис. 6.2 и 6.3. Первый случай соответствует когерентной обработке. Естественно, что наилучшим образом при этом обнаруживается точечная цель, причем выигрыш по отношению к распределенной (цель типа «г») при вероятности правильного обнаружения  $P_{\text{пр}} = 0,9$  составляет порядка 7 дБ по пороговому сигналу (суммарному отношению сигнал/шум для всей цели  $G$ ). На рис. 6.3 такие же характеристики приведены при условии, что из общего числа суммированных импульсов ( $N = 256$ ) когерентной обработке подвергаются пачки из 32 импульсов, после чего осуществляется 8 некогерентных накоплений. В этом случае ситуация обратная. При тех же требованиях наилучшие характеристики у распределенной цели (выигрыш достигает порядка 6 дБ). На рис. 6.4 изображены зависимости требуемого отношения сигнал/шум  $G$  для разных типов целей при различном сочетании числа когерентных  $N_{\text{кг}}$  и не когерентных  $N_{\text{кгп}}$  накоплений.




Рис. 6.2. Характеристика обнаружения (когерентная обработка)



Рис. 6.3. Характеристика обнаружения (обработка – частично когерентная;  $N_{\text{кг}} = 32$ ;  $N_{\text{нкг}} = 8$ )

Рис. 6.4. Требуемое отношение сигнал/шум

Все расчеты производились при следующих параметрах: высота полета носителя — 100 км; горизонтальная дальность — 200 км; длина волны — 0,1 м; скорость полета — 7,5 км/с; период повторения зондирующих импульсов — 1 мс; вероятность ложной тревоги —  $10^{-6}$ .

### 6.3. Литература к главе 6

1. Dorosinskiy L.G. The research of the distributed objects' radar image recognition algorithms. Applied and Fundamental Studies. Proceedings of the 2st International Academic Conference. March 8-10, 2013, St. Louis, Missouri USA, vol. 1. pp. 211-214.

2. Тимошенко С.И. Использование смешанного семейства распределений Пирсона и Джонсона для расчета вероятностных характеристик // Интернет-журнал «НАУКОВЕДИЕ» Том 9, № 3 (2017) <http://nakovedenie.ru/PDF/03TVN317.pdf>.

3. Доросинский Л.Г., Тимошенко С.И. Обнаружение целей на фоне помех в частично-когерентных РСА // Радиотехника.1994. М. с. 44-50.

---

## 7. ИЗМЕРЕНИЕ ПАРАМЕТРОВ РЛИ

Решение задачи классификации радиолокационных изображений ПРЦ сопровождается измерением параметров РЛИ, без измерения которых классификации ПРЦ невозможна. Среди таких параметров основными являются следующие.

Оценка центра РЛИ ПРЦ в пределах сформированного кадра.

Оценка области РЛИ, занимаемой радиолокационным изображением ПРЦ.

Оценка ракурса (пространственной ориентации ПРЦ относительно траектории космического аппарата).

Названные задачи рассмотрены в данной главе [18, 19].

### 7.1. Измерение общегрупповых параметров распределенной цели.

#### Измерение координат центра РЛИ

При решении задачи классификации, сопровождения траектории движения ордера ПРЦ или отдельной цели неизбежно возникает задача определения ряда общегрупповых параметров, таких как координата центра ордера (центра РЛИ ПРЦ), количество целей в составе ордера («блестящих точек» в составе ПРЦ), размеры ордера (размеры РЛИ ПРЦ), скорость и направление движения, ракурс и т. п.

##### 7.1.1. Синтез оптимального измерителя общегруппового параметра групповой цели

В настоящем разделе рассмотрено решение задачи оптимального измерения координаты общегруппового центра распределенной цели. Вся доступная информация о пространственном положении цели содержится в апостериорной плотности вероятности  $P(\bar{x}_c; \bar{x}_1 \dots \bar{x}_n; n)$ , где  $\bar{x}_c$  – координата общегруппового центра цели;  $n$  – число отсчетов полученного РЛИ,  $\bar{x}_1 \dots \bar{x}_n$  – пространственные координаты отдельных элементов группы относительно общегруппового центра.

Определяющее значение для решения задачи синтеза устройства оценки общегруппового центра имеет апостериорная плотность вероятности

$$P(\bar{x}_c) = \langle P(x_c; n; x_1 \dots x_n) \rangle_{n, \bar{x}}, \quad (7.1.1)$$

поскольку принятие решения заключается в определении какого-либо параметра названной плотности (математического ожидания, моды и т. д.), выбор которого зависит от принятого критерия (минимум среднеквадратической ошибки, максимум апостериорной вероятности и т. п.).

В выражении (7.1.1) усреднение производится по всем возможным значениям как числа элементов цели, так и комбинациям их пространственных координат.

При заданной априорной вероятности  $P(\bar{x}_c)$  и коэффициенте правдоподобия  $\Delta(\bar{U}/\bar{x}_c)$  выражение апостериорной плотности вероятностей определяется по формуле Байеса

$$P(\bar{x}_c) = CP(\bar{x}_c) \bar{\Delta}(\bar{U}/\bar{x}_c), \quad (7.1.2)$$

где  $\bar{U}$  – вектор комплексных амплитуд наблюдаемых данных.

Коэффициент правдоподобия в формуле (7.1.2) определяется статистическим усреднением частного коэффициента правдоподобия  $\Delta(\bar{U}/\bar{x}_{\Pi}; x_1, x_2, \dots, x_n)$ , записанного в предположении, что координаты элементов цели известны и фиксированы, по всем возможным значениям вектора  $\bar{x}_n = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n)$  координат отдельных точек ПРЦ

$$\bar{\Delta}(\bar{U}/\bar{x}_{\Pi}) = \Delta(\bar{U}/\bar{x}_{\Pi}; x_1, \bar{x}_2, \dots, \bar{x}_n)_{\bar{x}_n}. \quad (7.1.3)$$

Усреднение в (4.1.3) производится по плотностям вероятности

$$\pi_n(\bar{x}_1, \dots, \bar{x}_n; \Omega/\bar{x}_{\Pi}), \quad (7.1.4)$$

содержание которых заключается в следующем. Вероятность  $\Delta P_n$  нахождения в области пространства  $\Omega$ , занятой целью, ровно  $n$  целей, координаты которых попали в интервалы

$$(\bar{x}_1, \bar{x}_1 + \bar{\Delta}_1), \dots, (\bar{x}_n, \bar{x}_n + \bar{\Delta}_n)$$

при условии, что координата центра цели  $\bar{x}_{\Pi}$ , с точностью до величин второго порядка малости относительно  $\bar{\Delta} = \max_{1 \leq j \leq n} \bar{x}_j$ , выражаются в виде

$$\Delta P_n = \pi_n(\bar{x}_1, \dots, \bar{x}_n; \Omega) \bar{\Delta}_1, \dots, \bar{\Delta}_n [1 + o(\bar{\Delta})]. \quad (7.1.5)$$

При сделанных предположениях операция усреднения (7.1.3) может быть конкретизирована следующим образом:

$$\Delta[\bar{U}/\bar{x}_{\Pi}] = \sum_{n=0}^{\infty} \frac{1}{n!} \int_{(n)} \Delta_n(\bar{x}_n) \pi(\bar{x}_n/\bar{x}_{\Pi}) d\bar{x}_n. \quad (7.1.6)$$

Индекс  $(n)$  под интегралом указывает на его кратность, причем область интегрирования равна  $\Omega$ -интервалу возможных координат элементов цели.

Если сигналы разрешены по каждой из своих координат, то справедливо выражение:

$$\Delta_n(\bar{x}_n) = \prod_{i=1}^n \Delta_1(\bar{U}, \bar{x}_i) \quad (7.1.7)$$

и, следовательно, для (7.1.6) можно записать:

$$\Delta[U/x_n] = \sum_{n=0}^{\infty} \frac{1}{n!} \int_{(n)} \left\{ \prod_{i=1}^n \Delta_1(\bar{U}, \bar{x}_i) \right\} \pi_n(\bar{x}_n/\bar{x}_{\Pi}), \quad (7.1.8)$$

где  $\Delta_1(\bar{U}, \bar{x}_i)$  – коэффициент правдоподобия для цели, состоящей из одного элементарного отражателя с пространственной координатой  $\bar{x}_i$ .

В соответствии с методикой [1] вероятностной характеристикой для задания расположения элементов ПРЦ может служить производящий функционал

$$L(u) = \sum_{n=0}^{\infty} \frac{1}{n!} \int_{(n)} \pi\left(\frac{\bar{x}_n}{\bar{x}_{\Pi}}\right) \prod_{i=1}^n [u(\bar{x}_i) + 1] d\bar{x}_n. \quad (7.1.9)$$

Производящий функционал (7.1.9) позволяет выразить апостериорные характеристики многоэлементной цели в более компактной форме для ряда важных случаев. Это, в первую очередь относится к тем статистическим ситуациям, когда: цели разрешены по всем координатам, а априорные координаты отдельных элементов групповой цели представляют собой поток Пуассона или Бернулли.



Во избежание громоздких выкладок в дальнейшем подробно рассмотрим задачу в одномерном варианте, а именно, определим алгоритм оценки одной координаты общегруппового параметра цели (центра ПРЦ) и оценим его эффективность для ряда важных практических приложений. Такой подход по существу не снижает общности основных выводов и рекомендаций существенно упрощая решение задачи синтеза и анализа.

Сравнивая выражения (7.1.8) и (7.1.9), нетрудно установить следующее соотношение:

$$\Delta \left[ \frac{\bar{U}}{x_{ц}} \right] = L \left[ \Delta_1(u) - \frac{1}{x_{ц}} \right]. \quad (7.1.10)$$

Априорная информация о координатах отдельных элементов групповой цели задается ниже в двух вариантах:

- а) координаты отдельных целей представляют собой поток Пуассона;
- б) координаты отдельных целей аппроксимируются потоком Бернулли.

Для потока Пуассона производящий функционал получен в [2]:

$$L[u] = \exp \left\{ \int_{\Omega} \beta(x) u(x) dx \right\}, \quad (7.1.11)$$

где  $\beta(x)$  — интенсивность пуассоновского потока, заданная как функция от координаты цели.

Сравнение выражений (7.1.11) и (7.1.10) позволяет непосредственно получить выражение для усредненного коэффициента правдоподобия при моделировании отсчетов РЛИ ПРЦ пуассоновским потоком

$$\Delta \left[ \bar{U}/x_{ц} \right] = \exp \left\{ \int_{\Omega} \beta(x/x_{ц}) [\Delta_1(\bar{U}, x) - 1] dx \right\}. \quad (7.1.12)$$

Принятое для интенсивности потока обозначение  $\beta(x/x_{ц})$  подчеркивает зависимость интенсивности от измеряемого параметра — координаты центра сложной цели  $x_{ц}$ .

Для другого частного случая, когда поток координат элементов поверхности РЛИ ПРЦ аппроксимирован потоком Бернулли, выражение производящего функционала имеет вид:

$$L[u] = \prod_{j=1}^k \left[ 1 + \int_{\Omega} u(x) e_j(x) dx \right], \quad (7.1.13)$$

где  $k$  — максимальное число отдельных элементов групповой цели (число элементов разрешения, приходящихся на цель максимально возможных размеров);  $e_j(x)$  — частичная плотность вероятности наличия отражающего элемента на  $j$ -й позиции (с номером  $j$ ), не обязательно нормированная к единице, то есть

$$\int_{\Omega} e_j(x) dx = v_j \leq 1, \quad (7.1.14)$$

что допускает отсутствие отражающего элемента цели в  $j$ -м элементе разрешения с вероятностью

$$\mu_j = 1 - v_j. \quad (7.1.15)$$

Сравнение выражений (7.1.10) и (7.1.13) позволяет получить коэффициент правдоподобия

$$\Delta[\bar{U}/x_{\Pi}] = \prod_{j=1}^k \left[ 1 + \int_{\Omega} e_j(x/x_{\Pi}) [\Delta_1(\bar{U}, x_{\Pi}) - 1] dx \right]. \quad (7.1.16)$$

С учетом (7.1.14) и (7.1.15) последнее выражение может быть записано в следующем виде

$$\Delta[\bar{U}/x_{\Pi}] = \prod_{j=1}^k \left[ \mu_j(x) + \int_{\Omega} e_j(x/x_{\Pi}) \Delta_1(\bar{U}, x) dx \right]. \quad (7.1.17)$$

В тех случаях, когда решение принимается по критерию максимума апостериорной плотности вероятности, оценка координаты центра цели находится из выражения

$$\bar{x}_{\Pi} = \operatorname{argmax} \left\{ \ln P(x_{\Pi}) + \ln \Delta \left[ \frac{\bar{U}}{x_{\Pi}} \right] \right\} \quad (7.1.18)$$

и определяется формулами:  
для пуассоновского потока

$$\bar{x}_{\Pi} = \operatorname{argmax} \left\{ \ln P(x_{\Pi}) + \int_{\Omega} \beta(x/x_{\Pi}) [\Delta(\bar{U}, x) - 1] dx \right\}, \quad (7.1.19)$$

для потока Бернулли

$$x_{\Pi} = \operatorname{argmax} \left\{ \ln P(x_{\Pi}) + \sum_{j=1}^k \ln \left[ \mu_j(x) + \int_{\Omega} e_j(x/x_{\Pi}) \Delta_1(\bar{U}, x) dx \right] \right\}. \quad (7.1.20)$$

Соответствующие схемы изображены на рис. 7.1 и на рис. 7.2.




Рис. 7.1. Блок-схема измерителя координаты центра (поток Пуассона)

Как в том, так и другом случае основная функциональная операция состоит в обобщении данных оптимальных приемников первичной обработки (интегрировании по ожидаемой протяженности цели с весами, определяемыми априорным изменением интенсивности потока с соответствующим «загрублением» разрешающей способности).

Таким образом, для построения классического байесовского измерителя необходимо априорное знание интенсивности потока  $\beta(x/x_{\Pi})$  или парциальных плотностей  $e_j(x)$ , которые должны рассчитываться, исходя из принятых моделей отдельных ПРЦ и/или тактики построения.

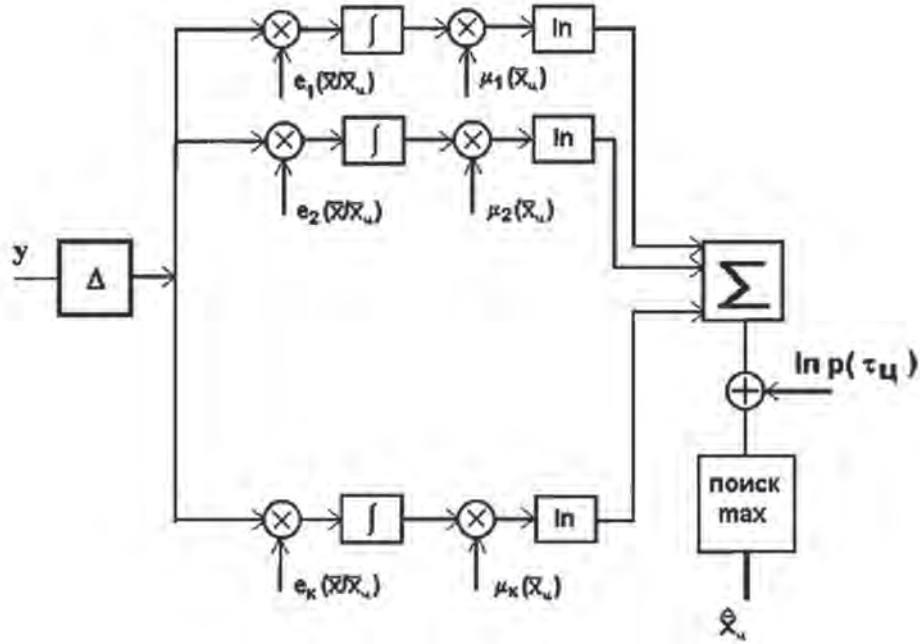


Рис. 7.2. Блок-схема измерителя координаты центра (поток Бернулли)

### 7.1.2. Анализ эффективности алгоритма измерения координаты центра ПРЦ

Оценка максимума апостериорной вероятности образуется путем выбора канала формирования  $\dot{P}(x_{ц})$ , в котором апостериорная плотность вероятности принимает максимальное значение. В частности, если известно приближение  $x'_{ц}$  к истинному значению  $x_{ц}$ , отстоящее от последнего меньше, чем на величину апостериорного среднеквадратичного разброса, удобно аппроксимировать  $\ln \dot{P}(x'_{ц})$  квадратичным разложением относительно точки  $x'_{ц}$ :

$$\ln \dot{P}(x_{ц}) \cong \ln \dot{P}(x'_{ц}) + \frac{d \ln \dot{P}(x'_{ц})}{dx_{ц}} (x - x'_{ц}) + \frac{d^2 \ln \dot{P}(x'_{ц})}{dx_{ц}^2} (x - x'_{ц})^2. \quad (7.1.21)$$

После дифференцирования по  $x_{ц}$  получаем решение уравнение правдоподобия

$$\hat{x}_{ц} = x'_{ц} - \frac{\frac{d}{dx_{ц}} \ln \dot{P}_1(x'_{ц})}{\frac{d^2}{dx_{ц}^2} \ln \dot{P}_1(x'_{ц})}. \quad (7.1.22)$$

При относительно невысокой априорной точности, когда априорное распределение практически неизменно в окрестности пика коэффициента правдоподобия  $\Delta[\bar{U}/x_{ц}]$ , переходим к оценкам максимального правдоподобия. При этом дисперсия оценки определяется соотношением

$$\sigma_{x_{ц}}^2 = -M \left\{ \left[ \frac{d \ln \dot{P}(U/x_{ц})}{dx_{ц}} \right] \right\}. \quad (7.1.23)$$

Применяя известную методику расчета дисперсии оценки [1], при аппроксимации последовательности отметок от цели пуассоновским потоком получим для нее следующее выражение:

$$\sigma_{x_{ц}}^{-2} = 2 \iint_{\Omega} \beta'(x_1/x_{ц}) \beta'(x_2/x_{ц}) \sqrt{q(x_1)q(x_2)} \psi(x_1, x_2) dx_1 dx_2, \quad (7.1.24)$$

где  $q(x)$  – отношение сигнал/шум, заданное как функция от координат цели;  $\psi(x_1, x_2)$  – функция неопределенности.

Дальнейшую конкретизацию выражения (7.1.24) проведем при следующих предположениях:

1) отношение сигнал/шум не зависит от координат цели, а необходимые энергетические соотношения учтены при определении интенсивности потока  $\beta(x)$ , которая, в свою очередь, представляет собой симметричную функцию;

2) оцениваемый общегрупповой параметр  $x_{ц}$  представляет собой координату центра интенсивности  $\beta(x)$ .

Для получения простых выражений, позволяющих произвести предварительную оценку эффективности определения общегруппового центра цели рассмотрим два частных случая.

1. При достаточно высоком разрешении воспользуемся аппроксимацией функции неопределенности

$$\psi(x_1, x_2) = \Delta_{\phi} \delta(x_1 - x_2). \quad (7.1.25)$$

Тогда,

$$\sigma_{x_{ц}}^{-2} = 2 \Delta_{\psi} \int_{\Omega} [\beta'(x - x_{ц})]^2 q(x) dx. \quad (7.1.26)$$

При постоянном значении отношения сигнал/шум:  $p = \text{const}$

$$\sigma_{x_{ц}}^2 = \frac{\Delta_{\beta 1}^2}{2q_{3\phi\phi}}, \quad (7.1.27)$$

где

$$\Delta_{\beta 1} = \frac{\sqrt{\int_{\Omega} \beta^2(x - x_{ц}) dx}}{\int_{\Omega} [\beta'(x - x_{ц})]^2 dx} \quad (7.1.28)$$

– эффективная протяженность групповой цели,

$$q_{3\phi\phi} = q \Delta_{\phi} \int_{\Omega} \beta^2(x - x_{ц}) dx \quad (7.1.29)$$

– эффективное общегрупповое отношение сигнал/шум.

2. В этом примере используем гауссовские функции для аппроксимации интенсивности потока и сигнальной функции (при вычислении функции неопределенности):

$$\beta(x) = L \exp \left[ -\frac{x^2}{2\Delta_{\beta 1}^2} \right]; \quad (7.1.30)$$

$$u(x) = M \exp\left[-\frac{x^2}{2\Delta_u^2}\right], \quad (7.1.31)$$

где коэффициенты  $L$  и  $M$  определяются из условий нормировки:

$$\int_{\Omega} \beta(x) dx = n, \quad (7.1.32)$$

$$\int_{\Omega} u^2(x) dx = 1. \quad (7.1.33)$$

После подстановки последних выражений в (5.1.24) получим:

$$\sigma_{x_{\Pi}}^2 = \frac{\Delta_{\beta 1}^2}{2pn^2} \frac{\left[1 + \left(\frac{\Delta_{\beta 1}}{\Delta_u}\right)^2\right]^{3/2}}{\left(\frac{\Delta_{\beta 1}}{\Delta_u}\right)^2}. \quad (7.1.34)$$

Минимум дисперсии оценки достигается при условии  $\frac{\Delta_{\beta 1}}{\Delta_u} = \sqrt{2}$  и равен

$$\sigma_{x_{\Pi}}^2 = 2,6 \frac{\Delta_{\beta 1}^2}{2qn^2}. \quad (7.1.35)$$

Несмотря на частный характер последних соотношений, можно сделать вывод достаточно общего характера: при определении центра группы мало связанных между собой слабых сигналов целесообразно иметь средство наблюдения с разрешающей способностью, сравнимой по размерам с эффективным размером группы. В практически важных случаях, связанных с классификацией ПРЦ, когда требуемая разрешающая способность существенно выше, оптимальный алгоритм определения центра формирует «стробы», «загрубляющие» разрешение до требуемой величины.

При использовании для моделирования отсчетов сигнала от цели в виде потока Бернулли для дисперсии оценки координаты центра получим аналогичное выражение

$$\sigma_{x_{\Pi}}^{-2} = 2 \sum_{j=1}^k \iint_{\Omega} e'_j(x_1/x_{\Pi}) e'_j(x_2/x_{\Pi}) \sqrt{q(x_1)q(x_2)} \Psi(x_1, x_2) dx_1 dx_2. \quad (7.1.36)$$

Предположим, что внутригрупповые сигналы могут находиться только на вполне определенных позициях, то есть:

$$e_j\left(\frac{x}{x_{\Pi}}\right) = v_j \delta(x - \Delta_j - x_{\Pi}) \quad (7.1.37)$$

и считая  $\psi(x_1, x_2) = \psi(x_1 - x_2)$ , получим:

$$\sigma_{x_{\Pi}}^{-2} = \sum_{j=1}^k v_j^2 \frac{2q_j}{\Delta_{\Phi}}, \quad (7.1.38)$$

где  $\Delta_{\Phi}$  — ширина интервала разрешения;  $q_j$  — отношение сигнал/шум в  $j$ -м интервале разрешения.



Формула (7.1.38) отражает в основном те же качественные особенности измерения общегруппового центра, что и при использовании потока Пуассона. Точность растет при увеличении отношения сигнал/шум и среднего числа элементарных целей. В то же время дисперсия увеличивается при увеличении числа элементов разрешения, приходящихся на размер групповой цели (при увеличении отношения протяженности цели к величине элемента разрешения).

## 7.2. Оценка области, занимаемой целью на РЛИ

Выделение области, занимаемой радиолокационным портретом ПРЦ на РЛИ, представляет собой известную задачу сегментации, методам решения которой посвящен ряд работ, в частности, [3–12, 13]. Традиционные алгоритмы сегментации реализуют такие методы, как пространственное дифференцирование, функциональная аппроксимация, высокочастотная фильтрация, пороговая обработка, двумерная линейная фильтрация и т. д. Практическое применение рассматриваемых методов в задаче распознавания ПРЦ на борту КА вряд ли осуществимо, в первую очередь, из-за их вычислительной сложности, с одной стороны, и из-за необходимости экспериментального подбора параметров (настройки алгоритмов с помощью оператора), с другой. Существенный недостаток традиционных алгоритмов – недостаточное внимание к принципиальной необходимости учета флуктуации РЛИ ПРЦ, а также к формализации методов анализа их эффективности и результатам такого анализа.

Указанные недостатки могут быть преодолены при разработке алгоритма сегментации на основе статистической модели РЛИ с использованием аппарата и методологии теории статистических решений.

Хорошей моделью для РЛИ в РСА с достаточно высоким разрешением может служить двумерное поле независимых отсчетов мощности отраженного сигнала, одномерные плотности вероятности которых отличаются для отсчетов, соответствующих отражениям от фона и от поверхности ПРЦ. В первом приближении примем допущение о том, что все отсчеты фона имеют плотность вероятности  $W_{\Phi}(U_{ij})$ , а цели –  $W_{\Omega}(U_{ij})$ . В этом случае оптимальный алгоритм оценивания области, занимаемой отсчетами цели, записанный по критерию максимального правдоподобия, будет иметь вид:

$$\hat{\Omega}_{\Omega} = \operatorname{argmax}_{\Omega_{\Omega}} \left\{ \sum_{i,j \in \Omega_{\Omega}} \ln \frac{W_{\Omega}(U_{ij})}{W_{\Phi}(U_{ij})} \right\}. \quad (7.2.1)$$

Реализация алгоритма (7.2.1) является чрезвычайно трудоемкой из-за необходимости перебора всех возможных границ области, внутри которой расположена цель. Однако, с учетом статистической независимости сигналов в отдельных каналах дальности, максимум выражения в фигурных скобках (7.2.1) может быть получен, если максимизировать каждое отдельное слагаемое

$$\sum_{i \in [n_{1j}, n_{2j}]} \ln \frac{W_{\Omega}(U_{ij})}{W_{\Phi}(U_{ij})} \quad (7.2.2)$$

для каждого канала дальности с номером  $j$  ( $n_{1j}$  и  $n_{2j}$  – граничные точки, разделяющие область фона и цели в  $j$ -м канале дальности). Таким образом, оптимальный алгоритм определения области, занимаемой целью, сводится к оптимальной оценке

совокупности пар точек в каждом канале дальности, в которых происходит изменение параметра распределения отсчетов сначала в «направлении фон-цель», а затем в «направлении цель-фон».

Оптимальный по максимуму функции правдоподобия алгоритм нахождения оценок координат граничных точек  $\hat{n}_{1j}$  и  $\hat{n}_{2j}$  в  $j$ -м канале дальности принимает вид:

$$(\hat{n}_{1j}, \hat{n}_{2j}) = \underset{\substack{n_{1j}=\overline{1, M-1} \\ n_{2j}=\overline{n_{1j}+1, M}}}{\operatorname{argmax}} \left\{ \sum_{i=n_{1j}}^{n_{2j}} \ln \frac{W_{\Pi}(U_{ij})}{W_{\Phi}(u_{ij})} \right\}. \quad (7.2.3)$$

Совокупность граничных точек  $n_{1j}, n_{2j}$  при каждом значении  $j$  образуют границу области  $\Omega$ , занимаемой целью соответствующего класса.

Определим структуру оптимального алгоритма для некоторых наиболее распространенных видов распределений одномерной плотности вероятности отсчетов РЛИ.

а) Распределение отсчетов РЛИ – экспоненциальное:

$$W(u_{ij}) = \sigma^{-1} \exp(-\sigma^{-1} U_{ij}), \quad (7.2.4)$$

причем его параметр  $\sigma$  пропорционален удельной ЭПР цели ( $\sigma_2$ ) или фона ( $\sigma_1$ ) в зависимости от того, расположен ли соответствующий отсчет в области цели  $\Omega_{\Pi}$  или фона  $\Omega_{\Phi}$ . При известных априори значениях параметров  $\sigma_1$  и  $\sigma_2$  алгоритм (7.2.3) может быть записан в виде:

$$(\hat{n}_{1j}, \hat{n}_{2j}) = \underset{\substack{n_{1j}=\overline{1, M-1} \\ n_{2j}=\overline{n_{1j}+1, M}}}{\operatorname{argmax}} \left\{ (n_{2j} - n_{1j}) \ln \frac{\sigma_1}{\sigma_2} - (\sigma_2^{-1} - \sigma_1^{-1}) \sum_{i=n_{1j}}^{n_{2j}} U_{ij} \right\}. \quad (7.2.5)$$

При неизвестных значениях параметров  $\sigma_1$  и  $\sigma_2$  функция правдоподобия в каждом канале дальности может быть определена по формуле (5.2.5), где вместо названных параметров используются их максимально правдоподобные оценки при каждом возможном значении координат граничных точек  $n_1$  и  $n_2$ . В этом случае алгоритм оценки координат граничных точек принимает вид:

$$\begin{aligned} (\hat{n}_{1j}, \hat{n}_{2j}) = \underset{\substack{n_{1j}=\overline{2, M-2} \\ n_{2j}=\overline{n_{1j}+1, M-1}}}{\operatorname{argmax}} & \left\{ -(n_{1j} - 1) \ln \left[ (n_{1j} - 1)^{-1} \sum_{i=1}^{n_{1j}-1} U_{ij} \right] - \right. \\ & \left. -(n_{2j} - n_{1j} - 1) \ln \left[ (n_{2j} - n_{1j} - 1)^{-1} \sum_{i=n_{1j}}^{n_{2j}} U_{ij} \right] - (M - n_{2j}) \ln \left[ (M - n_{2j})^{-1} \sum_{i=n_{2j}+1}^M U_{ij} \right] \right\}, \end{aligned} \quad (7.2.6)$$

и может быть назван адаптивным по отношению к параметрам распределения.

б) Распределение отсчетов РЛИ – гамма-распределение:

$$W(u_{ij}) = \frac{\gamma^n}{\Gamma(\eta)} u_{ij}^{\eta-1} \exp(-\gamma U_{ij})$$

с параметрами  $\gamma_2, \eta_2$  в области цели и параметрами  $\gamma_1, \eta_1$  в области, занятой фоном.

Рассмотрим два варианта:

1) на границе областей изменяется только параметр масштаба  $\gamma (\eta_2 = \eta_1 = \eta)$ . В этом случае алгоритм оценки граничных точек имеет вид:

$$(\hat{n}_{1j}, \hat{n}_{2j}) = \operatorname{argmax}_{\substack{n_{1j}=1, M-1 \\ n_{2j}=\overline{n_{1j}+1, M}}} \left\{ \eta_0 (n_{2j} - n_{1j}) \ln \frac{\gamma_2}{\gamma_1} - (\gamma_2 - \gamma_1) \sum_{i=n_{1j}}^{n_{2j}} U_{ij} \right\}; \quad (7.2.7)$$

2) на границе областей изменяется только параметр формы  $\eta (\gamma_2 = \gamma_1 = \eta_0)$ . Алгоритм выглядит следующим образом.

$$(\hat{n}_{1j}, \hat{n}_{2j}) = \operatorname{argmax}_{\substack{n_{1j}=1, M-1 \\ n_{2j}=\overline{n_{1j}+1, M}}} \left\{ (n_{2j} - n_{1j}) \left[ \ln \frac{\Gamma(\eta_1)}{\Gamma(\eta_2)} + (\eta_2 - \eta_1) \ln \gamma_0 \right] + \right. \\ \left. + (\eta_2 - \eta_1) \sum_{i=n_{1j}}^{n_{2j}} \ln U_{ij} \right\}. \quad (7.2.8)$$

Реализация рассмотренных алгоритмов не требует операций более сложных, нежели простое суммирование отсчетов РЛИ.

Достаточной статистикой при решении задачи многоальтернативной проверки гипотез о линейных размерах объекта является вектор, компонентами которого являются суммы отсчётов в пределах ожидаемых размеров объекта. В дальнейшем вектор обозначен

$$\lambda = \{\lambda_L, \lambda_M, \lambda_B\},$$

где 
$$\lambda_L = \sum_{i,j \in \Omega_L} U_{i,j}; \quad \lambda_M = \sum_{i,j \in \Omega_M} U_{i,j}; \quad \lambda_B = \sum_{i,j \in \Omega_B} U_{i,j};$$

$U_{i,j}$  — отсчёты изображения;  $\Omega_L, \Omega_M, \Omega_B$  — области изображения, занимаемые «малой», «средней» и «большой» целями.

Основной статистический материал, используемый для исследования алгоритмов распознавания, получен путём моделирования двумерных РЛИ, адекватных полю сигнала на выходе устройства обработки в станции бокового обзора с синтезированной апертурой [9]. Наблюдаемый объект моделируется с помощью отдельных блестящих точек и диффузионной составляющей. Распознаваемые классы отличаются размерами. Число классов равно трём. На рис. 7.3 представлен пример радиолокационного изображения, содержащего отдельные объекты, отличающиеся своими размерами, которые следует классифицировать по названному параметру.

Принимаемый сигнал формируется на выходе РЛС с синтезированной апертурой (рис. 7.4) и представляет собой совокупность случайных отсчётов, имеющих экспоненциальное распределение с заданной дисперсией в пределах области, занимаемой целью на изображении.



Рис. 7.3. Пример радиолокационного изображения




Рис. 7.4. Отсчёты изображений целей 3 классов, отличающихся размерами

В результате моделирования алгоритма классификации, описанного выше, получены вероятности правильного распознавания для РЛИ, отличающихся размерами в 1,5 раза

$$P_{q=10} = \begin{pmatrix} L/L & M/L & B/L \\ L/M & M/M & B/M \\ L/B & M/B & B/B \end{pmatrix}. \quad (7.2.9)$$

Каждый элемент матрицы представляет собой оценку вероятности правильной (ошибочной) классификации малых ( $L$ ), средних ( $M$ ) и больших ( $B$ ) целей. При разных отношениях мощностей отсчётов, принадлежащих целям, к мощности шума.

$$P_{q=8} = \begin{pmatrix} 0,0750 & 0,0750 & 0,0750 \\ 0 & 0,0240 & 0,0240 \\ 0 & 0 & 0,0030 \end{pmatrix};$$

$$P_{q=10} = \begin{pmatrix} 0,4940 & 0,4910 & 0,4860 \\ 0,0120 & 0,5500 & 0,5500 \\ 0 & 0,0190 & 0,4620 \end{pmatrix};$$

$$P_{q=12} = \begin{pmatrix} 0,8480 & 0,8450 & 0,8450 \\ 0,1290 & 0,9330 & 0,9320 \\ 0,0050 & 0,3940 & 0,9640 \end{pmatrix}.$$

На рис. 7.5. представлены зависимости вероятностей правильной классификации от отношения сигнал/шум и числа отсчётов сигнала, приходящихся на цель.




Рис. 7.5. Зависимость вероятности правильного обнаружения:  
а –  $M = \text{const}$ ; б –  $q = \text{const}$

На этих рисунках;  $P$  – вероятность правильного обнаружения;  $q$  – отношение сигнал-шум,  $M$  – количество отсчетов цели.



### 7.3. Оценка ракурса цели

Если определение области, занятой целью на РЛИ, представляет интерес при обучении алгоритма, формировании радиолокационных портретов ПРЦ и при достаточно большом отношении сигнал/фон, реализуемом на практике, может быть игнорировано, (отсчеты фона при верно выбранном пороге практически отсутствуют), то оценка ракурса в режиме эксплуатации алгоритма классификации принципиально необходима, ибо со сменой ракурса существенным образом меняется как интегральная ЭПР ПРЦ, так и ее индивидуальный радиолокационный портрет, что требует в общем случае обращения к вполне определенным (полученным при том же ракурсе) радиолокационным портретам из базы данных. Рассмотрим возможность оценки ракурса по ориентации контура ПРЦ (см. рис. 7.6).




Рис. 7.6. К выводу алгоритмов оценки области РЛИ, занимаемой ПРЦ, и ракурса цели

На рисунке показана условная область цели на РЛИ в координатах дальность – азимут. Продольная ось цели, которая в случае наблюдения ПРЦ совпадает с осью симметрии, у целей названного класса достаточно ярко выражена, поэтому ракурсом здесь и далее считаем угол наклона продольной оси к азимутальной координате  $\varphi$ . При известном угле азимута цели  $\theta_H$  ракурс определяется суммой

$$\varphi = \varphi_1 + \Theta_H - \frac{\pi}{2} \pm \pi.$$

Слагаемое  $\pm\pi$  вызвано неоднозначностью при оценке ракурса ПРЦ по ориентации его продольной оси.

Реальное радиолокационное изображение ПРЦ при его дискретизации по дальности и азимуту представляет собой совокупность точек так или иначе группирующихся вдоль продольной оси ПРЦ. Определение углового коэффициента такой прямой можно осуществить множеством способов, основанных на вычислении минимумов расстояний между точками и прямой, вычисленными в той или иной метрике. Всем этим методам в той или иной мере присущ общий недостаток, состоящий в том, что аномальные точки, расположенные далеко от прямой, дают наибольший вклад в формируемую сумму (расстояние до них самое большое) и оценка ракурса производится с заметной ошибкой. От названного недостатка свободен метод преобразований Хафа (кластерного анализа). Оставляя вопрос об эффективности различных методов до раздела, посвященного сравнительному анализу, рассмотрим содержание алгоритма Хафа. В результате работы алгоритма оценки граничных точек в каждом канале дальности (азимута) после дискретизации РЛИ ПРЦ образуется совокупность точек, большинство которых (за исключением аномальных, созданных фоном) группируется вдоль продольной оси ПРЦ, угловой коэффициент которой и является предметом оценки. Каждой точке с координатами  $x_i, y_i$  на плоскости  $XOY$  ставится в соответствие кривая  $p_i(\theta)$  на плоскости  $\theta, p$ . Методом пересчета служит нормальное уравнение прямой:

$$x_i \cos \theta + y_i \sin \theta = p. \quad (7.3.1)$$

В результате построения множества кривых для каждой точки  $x_i, y_i$  образуются области «сгущения» (кластеры), иначе говоря, области, через которые проходит большинство кривых. Точке центра такого кластера соответствует прямая, проходящая через большинство выделенных точек на плоскости РЛИ, при этом аномальные точки автоматически селектируются.

#### **7.4. Анализ алгоритмов оценки координат граничных точек между областями РЛИ с отличающимся контрастом**

Эффективность алгоритмов оценки координат граничных точек производилась методом статистического моделирования. Названным методом генерировалось выборочное РЛИ в одном канале дальности, содержащее 100 случайных отсчетов, первая половина которых имела плотность вероятности с одним параметром ( $\sigma_1$ ), а вторая половина – с другим ( $\sigma_2$ ). Величина ошибки  $\Delta_n$  рассчитывалась как сумма смещения и среднеквадратичного отклонения оценки координаты точки изменения параметра (вычисленная в количестве отсчетов РЛИ, что эквивалентно количеству элементов

разрешения). На рис. 5.7 показана зависимость ошибки от величины отношения ЭПР цели и фона в одном элементе разрешения  $\left(q = \frac{\sigma_2}{\sigma_1}\right)$ . Зависимости получены для следующих распределений отсчетов: 1 – гамма-распределение, 2 – экспоненциальное распределение (с известными априори параметрами) и 3 – экспоненциальное распределение с неизвестными параметрами. Из приведенного рисунка следует, что качество алгоритмов оценки граничных точек существенно зависит от вида распределения отсчетов РЛИ, причем названная зависимость тем сильнее, чем меньше радиолокационный контраст между поверхностью цели и МП. При этом экспоненциальное распределение представляет собой наименее благоприятную ситуацию для качественного воспроизведения цели. Однако, при контрасте более 8 дБ качество оценки координат граничных точек практически не зависит от вида распределения отсчетов и от наличия априорной информации об их параметрах. Адаптивный алгоритм в условиях произведенного моделирования практически не уступает оптимальному.

Зависимость ошибки  $\Delta_n$  от общего количества отсчетов показана на рис. 5.7. Очевидно, что уменьшение размеров фрагмента РЛИ, по которому принимается решение о наличии и координате скачка ЭПР, приводит к возрастанию ошибки. Кроме того, ошибка растет тем больше, чем дальше расположена точка скачка ЭПР от середины фрагмента, поскольку уменьшается число отсчетов и, следовательно, качество оценки одного из параметров распределения (рис. 7.7). Улучшение оценки второго параметра не компенсирует потерь, возникающих при оценке первого (При расположении скачка на краях фрагмента ошибка существенно выше).






Рис. 7.7. Средняя ошибка оценки координат граничных точек контура цели в зависимости от среднего радиолокационного контраста при нормальном распределении отсчетов РЛИ (1), гамма-распределении (2), экспоненциальном с известными (3) и неизвестными (4) параметрами


На рис. 7.8 показана оценка контура цели на РЛИ размером  $100 \times 100$ . Распределение отсчетов — экспоненциальное, алгоритм адаптивный.



а




б




в

Рис. 7.8. Пример оценки контура цели (а) адаптивным алгоритмом при двух значениях среднего радиолокационного контраста

Зависимость ошибки  $\Delta n$  от общего количества отсчетов показана на рис. 7.9. Очевидно, что уменьшение размеров фрагмента РЛИ, по которому принимается решение о наличии и координате скачка ЭПР, приводит к возрастанию ошибки. Кроме того, ошибка растет тем больше, чем дальше расположена точка скачка ЭПР от середины фрагмента, поскольку уменьшается число отсчетов и, следовательно, качество оценки одного из параметров распределения (рис. 7.7). Улучшение оценки второго параметра не компенсирует потерь, возникающих при оценке первого (При расположении скачка на краях фрагмента ошибка существенно выше).



а



б

Рис. 7.9. Зависимость ошибок оценки координат точек контура от размеров фрагмента (а) и расположения точек (б)

Для оценки длины цели в одном канале РЛИ определялись координаты двух точек изменения параметров РЛИ (начальной и конечной). Зависимость ошибки оценки длины  $\Delta_L$  от величины отношения параметров  $q$  показана на рис. 7.10. Ошибка  $\Delta_L$



вычислялась как сумма смещения и среднеквадратического отклонения длины цели в одном канале (усреднение производилось по 50 испытаниям). Из рисунка следует, что эффективность оптимального и адаптивного алгоритмов практически одинакова и составляет величину порядка одного отсчета при контрасте порядка 6–7 дБ.




Рис. 7.10. Ошибка оценки протяженности РЛИ цели в одном канале от величины среднего радиолокационного контраста при известных и неизвестных параметрах  $\sigma_1 \sigma_2$

## 7.5. Межобзорная идентификация РЛИ ПРЦ

Решение задачи классификации по одному наблюдению может оказаться недостаточно достоверным вследствие искажений РЛИ, вызванных его флуктуациями и рядом других причин особенно при большой мощности сигнала, отражённого от подстилающей поверхности. В таких случаях эффективность решения задачи может быть повышена за счет применения комплексного распознавания несколькими решающими автоматами (РА).

В связи с тем, что каждый РА содержит в своем банке наблюдаемых данных несколько РЛИ различных целей, возникает проблема их идентификации, иначе говоря, ответа на вопрос, какие конкретные фрагменты, содержащие отметки от целей в каждом из  $P$  различных обзоров, принадлежат одному и тому ПРЦ.

Предположим, что каждое  $j$ -е РЛИ, полученное в  $p$ -м обзоре, представлено вектором  $\bar{U}_{pj} = U_{pj}^i$ ;  $(p = \overline{1, P}; j = \overline{1, M}; i = \overline{1, N})$ , размерность которого  $N$  выбрана таким образом чтобы РЛИ ПРЦ наибольшего размера полностью размещалось в пределах заданного фрагмента МП. Нумерация фрагментов, наблюдаемых на радиолокационной карте (содержащихся в банке данных) производится по заданному правилу (в примере, показанном на рис. 7.11 слева – направо, сверху – вниз). При этом общая совокупность РЛИ, подлежащих идентификации, имеет вид:

$$\{U_{11}^1, \dots, U_{11}^N; \dots, U_{1M}^1, \dots, U_{1M}^N; \dots, U_{pj}^1, \dots, U_{pj}^N; \dots, U_{p1}^1, \dots, U_{p1}^N; \dots, U_{pM}^1, \dots, U_{pM}^N\}, \quad (7.5.1)$$

где первый индекс  $p$  – номер обзора; второй индекс  $j$  – номер РЛИ в  $p$ -м обзоре; третий индекс  $i$  – номер отсчета  $j$ -го РЛИ  $p$ -го обзора. Пусть  $j$ -е РЛИ определено вектором параметров  $\bar{l}_{p\alpha_j^p}$  ( $p = \overline{1, P}; \alpha_j^p = \overline{1, M}$ ), где  $p$  – по-прежнему номер обзора, а

$\alpha_j^p$  – истинный порядковый номер ПРЦ, соответствующего  $j$ -му РЛИ в  $p$ -м обзоре. Компонентами вектора  $l_{p\alpha_j^p}$  являются все доступные для анализа параметры объекта, в частности, статистические характеристики отсчетов РЛИ (математические ожидания, дисперсии и т. п.), траекторные параметры (координаты, скорости поступательного и вращательного движений и т. д.), оценки ЭПР, размеров и т. п.

Цель идентификации заключается в отыскании оптимальной в рамках выбранного критерия оценки совокупности векторов  $\hat{\alpha}_1, \dots, \hat{\alpha}_M$ , у которых каждая компонента  $\hat{\alpha}_i^p$  представляет собой оценку истинного номера  $j$ -й цели в  $p$ -м обзоре. На уже упоминавшемся примере (рис. 7.11) условно показаны карты анализируемой поверхности в трех последовательных обзорах. На каждой из этих карт расположены три РЛИ ПРЦ, которые условно изображены в виде треугольника, квадрата и круга. При простейшей идентификации целей (например, по минимуму изменения расстояния от отметки в предыдущем обзоре) второй и третий ПРЦ во втором обзоре будут перепутаны (они поменялись местами за счет перемещения по неизвестным для наблюдателя траекториям, изменения ракурса, траектории ИСЗ и т. п.). Правильное же решение должно иметь вид:

$$\begin{aligned}\hat{\alpha}_1^1 &= \hat{\alpha}_1^2 = \hat{\alpha}_1^3 = 1; \\ \hat{\alpha}_2^1 &= \hat{\alpha}_2^3 = 2; \quad \hat{\alpha}_2^2 = 1; \\ \hat{\alpha}_3^1 &= \hat{\alpha}_3^3 = 3; \quad \hat{\alpha}_3^2 = 2.\end{aligned}$$




Рис. 7.11. Карты поверхности с РЛИ трех разных ПРЦ

Общее число возможных гипотез об истинном расположении ПРЦ в пределах анализируемых карт акватории, полученных при  $P$  обзорах, равно  $P \cdot M!$ . Если для каждой из гипотез может быть записана ее апостериорная плотность вероятности, то решения следует принимать по ее максимуму:

$$\hat{\alpha}_1, \dots, \hat{\alpha}_M = \arg \max_{\bar{\alpha}_1, \dots, \bar{\alpha}_M} W(\bar{U}_1, \dots, \bar{U}_M / \bar{l}_{1\alpha_1^1}, \dots, \bar{l}_{p\alpha_M^p}). \quad (7.5.2)$$

В тех случаях, когда векторы параметров  $\bar{l}_{p\alpha_j^p}$  априори неизвестны, их значения в должны быть заменены соответствующими оценками максимального правдоподобия, полученными в предположении о справедливости проверяемой гипотезы.

Проиллюстрируем решение названной задачи на примере флуктуационных РЛИ ПРЦ, причем при идентификации отсутствует какая-либо априорная информация за исключением того факта, что отсчеты РЛИ независимы и распределены по экспоненциальному закону, что соответствует выборочным отсчетам мощности. В этом

случае параметры  $l_{p\alpha_j^p}^i = \sigma_{\alpha_j}^i$  представляют собой дисперсии соответствующих отсчетов. Алгоритм принимает вид:

$$\hat{\alpha}_1, \dots, \hat{\alpha}_M = \arg \max_{\hat{\alpha}_1, \dots, \hat{\alpha}_M} \left\{ \prod_{p=1}^P \prod_{j=1}^M \prod_{i=1}^N \frac{1}{\sigma_{\alpha_j}^i} \exp \left( -\frac{U_{pj}^i}{\sigma_{\alpha_j}^i} \right) \right\}. \quad (7.5.3)$$

Поскольку значения мощностей отдельных отсчетов априори неизвестны и при решении задачи идентификации отсутствует возможность их определения откуда-либо, кроме как из наблюдаемой совокупности РЛИ различных ПРЦ, воспользуемся максимально правдоподобными оценками неизвестных мощностей:

$$\hat{\sigma}_{\alpha_j}^i = \frac{1}{P} \sum_{p=1}^P U_{p\alpha_j^p}^i. \quad (7.5.4)$$

После подстановки (5.5.4) в (5.5.3) и (5.5.2) и логарифмирования получаем алгоритм идентификации РЛИ ПРЦ при межобзорном наблюдении:

$$\hat{\alpha}_1, \dots, \hat{\alpha}_M = \arg \min_{\hat{\alpha}_1, \dots, \hat{\alpha}_M} \left\{ \sum_{p=1}^P \sum_{j=1}^M \sum_{i=1}^N \left[ \frac{U_{pj}^i}{\frac{1}{P} \sum_{p=1}^P U_{p\alpha_j^p}^i} + \ln \left( \frac{1}{P} \sum_{p=1}^P U_{p\alpha_j^p}^i \right) \right] \right\}. \quad (7.5.5)$$

Для анализа эффективности предлагаемого правила рассмотрен пример идентификации двух РЛИ ПРЦ ( $M = 2$ ), которые моделировались в 4 ( $P = 4$ ) последовательных обзорах. РЛИ ПРЦ не отличались по величине удельной ЭПР, но отличались размерами (при общем размере радиолокационной карты  $100 \times 100$  элементов разрешения площадь первого РЛИ –  $5 \times 5$ , а второго –  $4 \times 4$  элементов разрешения). Положение центра РЛИ ПРЦ на карте в каждом обзоре моделировалось равновероятным при условии, что контуры РЛИ не пересекаются.

Таким образом, в каждом отдельном испытании были реализованы восемь конкурирующих гипотез о порядке последовательного размещения РЛИ на карте акватории.

Зависимости вероятностей ошибок от отношения сигнал/фон приведены на рис. 7.12, откуда, в частности, следует, что две цели с одинаковыми ЭПР (наихудший для практики случай) и отличающиеся по линейным размерам приблизительно на 25 % идентифицируются с вероятностью ошибки не более 0,1 при отношении сигнал/фон порядка 20 дБ.




Рис. 7.12. Вероятность ошибки идентификации

## 7.6. Оценка радиолокационного портрета ПРЦ

Проблема создания банка данных РЛИ ПРЦ является основной при реализации алгоритма классификации, поскольку именно от количества и достоверности априорной информации зависит в конечном счёте эффективность решения задачи в целом.

В данном разделе рассматривается алгоритм многомерной оценки амплитуд отражённых сигналов и угловых координат их источников, реализующий многоканальную (по числу пеленгуемых источников) итеративную процедуру измерения по методу максимального правдоподобия и отличающийся сравнительно несложной технической реализацией [14].

Предположим, что наблюдение поля сигналов и помех производится эквидистантной антенной решеткой, длина которой  $L$ , а число приемных элементов  $M$ . Тот факт, что названная решётка создаётся в виде искусственного раскрыва, не оказывает влияния на решение задачи, так как в течение времени синтеза параметры отражённых сигналов остаются практически неизменными, а это значит, что и принимаемые комплексные амплитуды остаются в пределах интервала синтеза неизменными. Очевидно, что принимаемые комплексные амплитуды в каждой точке траектории должны запоминаться на всё время работы алгоритма. При  $N$  источниках сигналов, находящихся в дальней зоне приемной антенны и отличающихся своими комплексными амплитудами  $f_i$  и угловыми направлениями  $\Theta_i$  ( $i = 1, N$ ), вектор комплексных амплитуд в элементах решетки может быть представлен в виде

$$U = \sum_{i=1}^n f_i S(\mu_i) + N, \quad (7.6.1)$$

$$\text{где} \quad S(\mu_i) = \|S_i(\mu_i)\| = \left\| \exp \left[ -j \frac{4\pi}{N-1} l \mu_i \right] \right\|; \quad \mu_i = \frac{L}{\lambda} \sin \Theta_i \quad (7.6.2)$$

— нормированная угловая координата  $i$ -го источника ( $\lambda$  — длина волны);  $N$  — вектор комплексных амплитуд помехи в элементах антенны.

Считая амплитуды отражённых сигналов и угловые координаты источников независимыми неизвестными величинами, помеху гауссовой с нулевым математическим ожиданием и корреляционной матрицей  $R_{\text{ш}} = M\{NN^*\}$ , запишем функцию правдоподобия для неизвестных параметров сигналов  $f_i$  и  $\mu_i$  ( $i = 1, N$ ):

$$P\{U/f_1, \dots, f_n; \mu_1, \dots, \mu_n\} = \text{const} \exp \left\{ -\frac{1}{2} \left[ U - \sum f_i X(\mu_i) \right]^{*T} R_{\text{ш}}^{-1} \left[ U - \sum f_i X(\mu_i) \right] \right\}, \quad (7.6.3)$$

где  $*$  — знак эрмитова сопряжения.

Преобразуем показатель (7.6.3) таким образом, чтобы выделить член, зависящий от амплитуды и угловой координаты только одного, например,  $m$ -го источника:

$$L_m = \frac{1}{2} |f_m|^2 S^{*T}(\mu_m) R_{\text{ш}}^{-1} S(\mu_m) - f_m U_m^{*T} R_{\text{ш}}^{-1} S(\mu_m) + F_m(f_1, \dots, f_{m-1}, f_{m+1}, \dots, f_N; \mu_1, \dots, \mu_{m-1}, \mu_{m+1}, \dots, \mu_N), \quad (7.6.4)$$

$$\text{где} \quad U_m = U - \sum_{\substack{i=1 \\ i \neq m}}^n f_i S(\mu_i); \quad (7.6.5)$$

$F_m(\bullet)$  — функция, не зависящая от  $f_m$  и  $\mu_m$ .

Для определения оценок максимального правдоподобия амплитуды и угловой координаты  $m$ -го отражающего элемента необходимо отыскать минимум выражения (7.6.4) по названным переменным. Преобразовав (7.6.4) к виду

$$L_m = S^{*T}(\mu_m) R_{\text{ш}}^{-1} S(\mu_m) \left| f_m - \frac{U_m^{*T} R_{\text{ш}}^{-1} S(\mu_m)}{S^{*T}(\mu_m) R_{\text{ш}}^{-1} S(\mu_m)} \right|^2 - \frac{|U_m^{*T} R_{\text{ш}}^{-1} S(\mu_m)|^2}{S^{*T}(\mu_m) R_{\text{ш}}^{-1} S(\mu_m)} + F_m \quad (7.6.6)$$

замечаем что, максимум функции правдоподобия имеет при условии

$$\hat{f}_m = \frac{U_m^{*T} R_{\text{ш}}^{-1} S(\mu_m)}{S^{*T}(\mu_m) R_{\text{ш}}^{-1} S(\mu_m)}. \quad (7.6.7)$$

Подставляя найденную оценку амплитуды (7.6.7.) в выражение (7.6.4) и дифференцируя по  $\mu_m$ , получаем уравнение правдоподобия для оценки углового направления

$$\operatorname{Re} \left\{ \frac{U_m^{*T} R_{\text{ш}}^{-1} V S(\mu_m)}{U_m^{*T} R_{\text{ш}}^{-1} S(\mu_m)} \right\} \Big|_{\mu_m = \hat{\mu}_m} = 0, \quad (7.6.9)$$

где  $V = 2\pi j / (N-1)$  ( $\operatorname{diag}(1, 2, \dots, N)$  — диагональная матрица).

Уравнение (7.6.8) легко решается численными методами, либо разложением в степенной ряд в окрестности оцениваемого значения.

Оценки параметров других сигналов находятся аналогично, причем перед оценкой  $m$ -го сигнала по формулам (7.6.7), (7.6.8) используются соответствующие оценки всех остальных  $n-1$  сигналов с целью компенсации «мешающих» для текущей оценки сигналов во входных данных  $m$ -го канала измерения.

Структурная схема оптимального алгоритма (рис. 7.13) состоит из  $n$  перекрестно связанных каналов, в каждом из которых производится вычитание оценок мешающих сигналов, полученных в соседних каналах, измерение «своих» параметров  $f$  и  $\mu$  формирование оценки  $\hat{f}S(\hat{\mu})$  «своего» сигнала, которая используется для соответствующей компенсации в других каналах.




Рис. 7.13. Структурная схема измерений



Эффективность алгоритма исследовалась методом статистического моделирования на примере решения задачи измерения координат двух источников с угловыми направлениями  $\mu_1 = 0,2$  и  $\mu_2 = -0,2$ , что соответствует их разнесению на 0,23 ширины диаграммы направленности антенной решетки по нулям (рис. 7.14). В качестве начальных условий задавались значения  $\mu_{0,2} = \pm 0,1$  (кривая 1),  $\mu_{0,2} = \pm 0,05$  (кривая 2),  $\mu_{0,2} = \pm 0,01$  (кривая 3). Шумы в элементах решетки некоррелированы. Отношение амплитуды сигнала к СКО шума 20 дБ. Оценки координат сходятся к истинным после 15...20 итераций при отличии заданных значений координат от начальных условий алгоритма в 10 и более раз.




Рис. 7.14. Сходимость оценок координат источников

Таким образом, даже в тех случаях, когда сигналы не разрешаются по углу (в смысле релеевого критерия) при отношениях сигнал — шум, не существенно превышающих порог обнаружения, рассматриваемый алгоритм позволяет производить совместное измерение угловых координат при низких требованиях к точности установки начальных условий.

## 7.7. Компенсация отражений от источников помех

Проблема построения оптимального алгоритма обнаружения сигналов в радиолокаторе с синтезированной апертурой при наличии мешающих отражений от местных предметов, а также разработка методики оценки эффективности такого обнаружения является одной из основных при проектировании и построении систем дистанционного мониторинга земной и водной поверхности воздушными и космическими средствами наблюдения с синтезированной апертурой.

### 7.7.1. Разработка алгоритма

В работах [15, 16], посвящённых проблемам обработки сигналов в радиолокационной станции с синтезированной апертурой (РСА), основное внимание уделялось исследованию алгоритмов обнаружения при действии помех, вызванных отражениями от подстилающей поверхности и шумом. В ряде практических ситуаций вместе с полезным сигналом, отраженным от многоэлементной цели, в диаграмме направленности (ДН) РСА могут присутствовать достаточно мощные помеховые сигналы,

вызванные отражениями от мешающих объектов. В этих случаях алгоритм обработки должен строиться с учётом, как распределённого характера цели, так и наличия помех. Определение основных принципов построения таких алгоритмов и методов их анализа составляет содержание данной работы.

Предположим, что РСА бокового обзора перемещается по прямолинейной траектории. Полезные и мешающие сигналы в одном элементе разрешения по дальности формируются отдельными отражателями, отстоящими на расстоянии  $d_i^T$  ( $i=\overline{1,n}$ ) и  $d_i^C$  ( $i=\overline{1,N}$ ) от начала координат с шагом  $\Delta d$ , причём  $n$  и  $N$  — числа сигнальных и помеховых отражателей соответственно (рис. 7.15). При дискретной во времени обработке вектор наблюдаемых данных может быть представлен в следующем виде:

$$Y = \beta_T A_T + \beta_C A_C + N_N, \quad (7.7.1)$$

где  $\beta_T$  — матрица  $M \times n$ :

$$\beta_T = X(d_1^T), \dots, X(d_n^T), \quad (7.7.2)$$

состоящая из векторов

$$X(d_n^T) = \exp\left(-j \frac{4\pi}{\lambda R_0} d_n^T r_k\right), \quad (7.7.3)$$

задающих фазовое распределение сигнала, отражённого от  $i$ -го элемента цели, по точкам синтезированной апертуры, имеющим координаты  $r_k$ ,  $k=\overline{1,M}$ , ( $\lambda$  — длина волны);  $A_T$  и  $A_C$  — векторы комплексных амплитуд сигналов и помех размерностью  $n \times 1$  и  $N \times 1$  соответственно, представляющие собой нормальные случайные величины с нулевыми математическими ожиданиями и дисперсиями  $\sigma_n^2$  и  $\sigma_{C_i}^2$  соответственно; матрица  $\beta_C$  определяется аналогично (7.7.2) и (7.7.3),  $N_N$  — вектор комплексных амплитуд гауссовского шума.

При записи наблюдаемых данных в виде (7.7.1) достаточной статистикой для обнаружения полезного сигнала является квадратичная форма

$$\alpha = Y^* T \theta Y, \quad (7.7.4)$$

где  $\theta = -R_{TC}^{-1}$  — весовая функция обработки,

$$R_{TC}^{-1} = \beta_T Q_T \beta_T^{*T} + R_N; \quad (7.7.5)$$

$$R_C^{-1} = \beta_C Q_C \beta_C^{*T} + R_N, \quad (7.7.6)$$

где  $R_{TC}$  и  $R_C$  — корреляционные матрицы вектора (7.7.1) при наличии и отсутствии полезного сигнала соответственно,

$$Q_T = \text{diag}(\sigma_{T_1}^2, \dots, \sigma_{T_n}^2); \quad (7.7.7)$$

$$Q_C = \text{diag}(\sigma_{C_1}^2, \dots, \sigma_{C_N}^2); \quad (7.7.8)$$

$$R_N = \sigma_N^2 E, \quad (7.7.9)$$

где  $*$  — комплексное сопряжение;  $T$  — знак транспонирования;  $E$  — единичная матрица, без ограничения общности в дальнейшем считаем дисперсию шума  $\sigma_N^2 = 1$ .




Рис. 7.15. Геометрия задачи

Используя равенство Вудбери для определения оптимальной весовой функции, запишем выражение достаточной статистики в виде

$$\alpha = Z^T P Z, \quad (7.7.10)$$

где

$$P = (E + Q_T \beta_T^{*T} R_C^{-1} \beta_T)^{-1} Q_T; \quad (7.7.11)$$

$$R_C^{-1} = E - \beta_C (E + \beta_C Q_C \beta_C^{*T})^{-1} Q_C \beta_C^{*T}; \quad (7.7.12)$$

$$Z = Y^T R_C^{-1} \beta_T^* = Y^T X^* (d_i^T) - \sum_{l=1}^N \chi_{li} Y^T X^* (d_l^C); \quad (7.7.13)$$

$$\chi_{li} = \sum_{t=1}^n p_{lt} X^T (d_t^C) X^* (d_i^C), \quad (7.7.14)$$

где  $p_{lt}$  — элемент матрицы (7.7.11).

Структурная схема, реализующая оптимальный алгоритм (7.7.10), показана на рис. 7.16.

Основная функциональная операция, входящая в (7.7.13):

$$Y^{T*} X (d_i) = \sum_{k=1}^M \exp \left( -j \frac{4\pi}{\lambda R_0} d_i r_k \right) \quad (7.7.15)$$

представляет собой ЛЧМ-демодуляцию и дискретное преобразование Фурье, вычисляемое для пространственных частот  $2d_i/\lambda R_0$ , соответствующих всем элементам цели (помех).




Рис. 7.16. Структурная схема оптимального алгоритма

### 7.7.2. Анализ алгоритма

Относительный выигрыш оптимальной обработки по сравнению с традиционной в РСА не позволяет оценить абсолютные значения характеристик обнаружения при многоэлементных источниках сигнала и помех. С другой стороны, точный расчёт названных характеристик связан со значительными вычислительными трудностями, возникающими при определении и интегрировании распределённой статистики (7.7.10). В связи с этим для оценки эффективности рассматриваемого алгоритма использована методика, основанная на границе Чернова [3], в соответствии с которой вероятности правильного обнаружения и ложной тревоги могут быть рассчитаны по формулам:

$$P_D = 1 - \exp \left[ \gamma(v(s) + (1-s)\dot{v}(s) + 0,5(1-s)^2 \ddot{v}(s)) \right] \times \operatorname{erfc} \left[ (1-s)\sqrt{\gamma\dot{v}(s)} \right]; \quad (7.7.16)$$

$$P_F = \exp \left[ \gamma(v(s) + s\dot{v}(s) + 0,5s^2 \ddot{v}(s)) \right] \times \operatorname{erfc} \left[ s\sqrt{\gamma\dot{v}(s)} \right], \quad (7.7.17)$$

$$\text{где} \quad v(s) = \ln \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \left[ P \left( \frac{Y}{T+C} \right) \right]^2 [P(Y/C)]^{1-s} dY, \quad (7.7.18)$$

$\dot{v}(s)$  и  $\ddot{v}(s)$  — первая и вторая производные от (7.7.18),  $s = 0 \dots 1$  — фиктивный параметр,  $\gamma$  — число независимых испытаний (практически для РСА — это количество используемых

частот при многочастотном зондировании или число некогерентно суммируемых синтезированных изображений при частично когерентном режиме работы PCA),  $P(Y/(T+C))$ ,  $P(Y/C)$  – плотности вероятностей наблюдаемого вектора при наличии и отсутствии полезного сигнала.

Для случая, рассматриваемого в работе, выражение (7.7.18) имеет вид

$$\begin{aligned} v(s) = & -0,5 \cdot \ln(\det(R_T) \cdot s + \det(R_C) \cdot (1-s)) + \\ & + 0,5s \cdot \ln(\det(R_T)) + 0,5 \cdot (1-s) \cdot \ln(\det(R_C)). \end{aligned} \quad (7.7.19)$$

По формулам (7.7.16) и (7.7.17) с учётом выражения (7.7.19) и его производных рассчитаны рабочие характеристики и характеристики обнаружения.

Рабочие характеристики, приведенные на рис. 7.17–7.19 построены для случая, когда имеется лишь одна цель и одна помеха,  $\sigma_T^2 = \sigma_C^2 = \sigma_N^2 = 1$ , а число периодов наблюдения  $M = 1300$ . На графиках также приведены рабочие характеристики для случаев отсутствия помехи и обработки, не использующей представленный в статье алгоритм.

На рис. 7.17 приведены кривые для различных значений расстояния между целью и помехой  $\Delta d$  при  $\gamma = 1$ . По графику видно, что обработка с применением описанного в статье алгоритма позволяет улучшить характеристики обнаружения даже при  $\gamma = 1$ . С увеличением расстояния между целью и помехой, начиная с 10 м, рабочая характеристика приближается к случаю, когда помеха отсутствует полностью.




Рис. 7.17. Рабочие характеристики для переменного значения  $\Delta d$



На рис. 7.18 и 7.19 приведены кривые для различных значений числа испытаний  $\gamma$  при  $\Delta d = 20$  м для разных интервалов по оси абсцисс. С увеличением числа независимо проведенных испытаний  $\gamma$  характеристики обнаружения имеют существенный выигрыш в сравнении с обработкой без компенсации помех.




Рис. 7.18. Рабочие характеристики для переменного значения  $\gamma$




Рис. 7.19. Рабочие характеристики для переменного значения  $\gamma$

Характеристики обнаружения многоэлементной цели ( $n = 5$ ) на фоне многоэлементной помехи ( $N = 5$ ) при  $\sigma_N^2 = 1$ ,  $\sigma_C^2 = \{0,1; 1; 0,1; 0,7; 0,5\}$ ,  $M = 100$ ,  $\gamma = 2$  для помеховых ситуаций с различными взаимными угловыми расположениями цели и помех (рис. 7.20) приведены на рис. 7.21. Из представленных кривых следует, что при большем пространственном разделении цели и помех алгоритм позволяет существенно повысить вероятность обнаружения цели.




Рис. 7.20. Ситуации взаимного расположения многоэлементной цели и помех

### 7.8. Интерферометрические РСА для измерения высот целей

Интерферометрическая РСА формирует два радиолокационных изображения с помощью антенн, разнесённых по высоте. Названные изображения сравниваются между собой для получения информации о высоте местности. Интерферометрические РСА могут быть выполнены на одном носителе с двумя антеннами (при этом карта высот формируется за один пролёт носителя РСА) или на одном носителе, но с формированием изображения за два пролёта над одним и тем же участком наблюдаемой поверхности.

Интерферометрические РСА с формированием изображения за два прохода обладают очевидным недостатком, связанным с необходимостью очень точно синхронизировать

положения антенн и возможностью изменения состояния поверхности между пролётами, так как такое время может составлять часы и более.

В интерферометрических РСА, формирующих РЛИ за один пролёт состояние участка поверхности абсолютно одинаково, база (расстояние между антеннами) фиксирована и неизменна.

Для понимания теоретических основ работы интерферометрических РСА рассмотрим две антенны, разнесённые по вертикали на расстояние  $L$  (рис. 7.22).

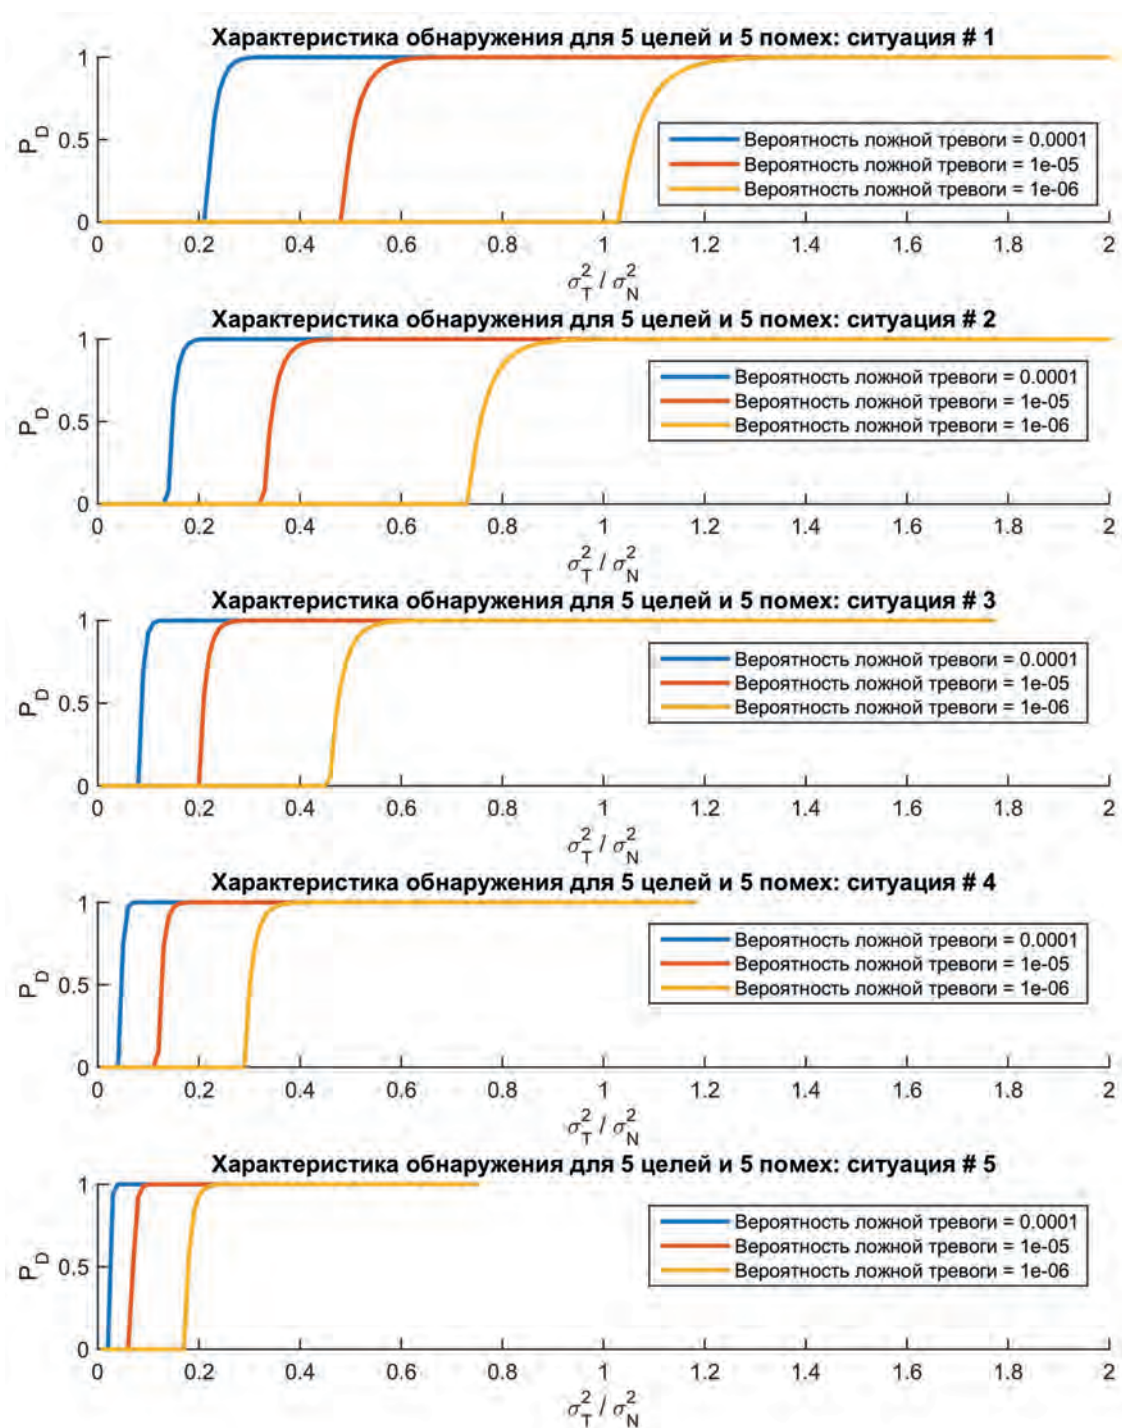


Рис. 7.21. Характеристики обнаружения многоэлементной цели

Определим оптимальный алгоритм определения высоты  $y$  по данным двух каналов приёма, разнесённых по вертикали на величину  $L$ : Напряжения на входах названных каналов определяются выражениями:

$$u_{in}^1(t) = A_i^1 \cos \left[ \omega_0 (t - \tau_{in}^1) + \phi_i^1 \right];$$

$$u_{in}^2(t) = A_i^2 \cos \left[ \omega_0 (t - \tau_{in}^2) + \phi_i^2 \right],$$

где  $A_i^1, A_i^2$  — амплитуды сигналов от  $i$ -й точки цели в первом и втором приёмниках, разнесённых по вертикали на расстояние  $L$ ;  $\tau_{in}^1, \tau_{in}^2$  — запаздывания сигналов от  $i$ -й точки цели в первом и втором приёмниках в  $n$ -й точке траектории ЛА;  $\phi_i^1, \phi_i^2$  — начальные фазы сигналов от  $i$ -й точки цели в первом и втором приёмниках.

Запишем выражения для запаздывания в первом и втором приёмниках:

$$\begin{aligned} \tau_{in}^1 &\approx \frac{2}{c} \sqrt{R_\Gamma^2 + (H - h_i)^2 + (nvT - x_i)^2} = \\ &= \frac{2}{c} \sqrt{R_\Gamma^2 + H^2 - 2Hh_i + h_i^2 + (nvT)^2 - 2x_i(nvT) + x_i^2} \approx \\ &\approx \frac{2R}{c} \left( 1 - \frac{Hh_i}{R^2} + \frac{(nvT)^2}{2R^2} - \frac{x_i(nvT)}{R^2} \right); \end{aligned} \quad (7.8.1)$$

$$\begin{aligned} \tau_{in}^2 &\approx \frac{2}{c} \sqrt{R_\Gamma^2 + (H + L - h_i)^2 + (nvT - x_i)^2} = \\ &= \frac{2}{c} \sqrt{R_\Gamma^2 + H^2 - 2H(L - h_i) + (L - h_i)^2 + (nvT)^2 - 2x_i(nvT) + x_i^2} \approx \\ &\approx \frac{2R}{c} \left( 1 - \frac{Hh_i}{R^2} - \frac{Lh_i}{R^2} + \frac{(nvT)^2}{2R^2} - \frac{x_i(nvT)}{R^2} \right), \end{aligned} \quad (7.8.2)$$

где  $x_i$  — координата точки цели, которую в дальнейшем считаем равной 0; множитель  $\frac{(nvT)^2}{2R^2}$  — компенсируется при обработке (традиционная ЛЧМ-демодуляция отражённых сигналов в РСА).




Рис. 7.22. Траектории интерферометрической РСА

С учётом выражений (7.8.1) и (7.7.2) комплексные амплитуды сигналов, принимаемых первым и вторым приёмником, имеют вид:

$$\dot{V}_1 = \dot{A}_1 e^{-j\frac{4\pi}{\lambda R}hH} + \dot{B}_1; \quad (7.8.3)$$

$$\dot{V}_2 = \dot{A}_2 e^{-j\frac{4\pi}{\lambda R}hH - j\frac{4\pi}{\lambda R}hL} + \dot{B}_2, \quad (7.8.4)$$

где  $\dot{A}_1 = A_1 e^{j\varphi_1}$ ;  $\dot{A}_2 = A_2 e^{j\varphi_2}$  – комплексные амплитуды сигналов, отражённых от точки поверхности, имеющей высоту  $h$ ;  $\dot{B}_1, \dot{B}_2$  – комплексные амплитуды шума с нулевыми математическими ожиданиями и дисперсиями  $\sigma_u^2$ .

В дальнейшем считаем  $\dot{A}_1 \approx \dot{A}_2$ , так как дальности до точки цели и ракурсы её наблюдения практически одинаковы  $L \ll R$ .

Для получения оптимального алгоритма оценивания высоты точки цели  $h$  запишем функцию правдоподобия:

$$W\left(\frac{h}{\dot{V}_1, \dot{V}_2}\right) = \frac{1}{2\pi|\Phi|^{1/2}} e^{-\frac{1}{2}V^{*T}\Phi^{-1}V}, \quad (7.8.5)$$

где 
$$V = \begin{pmatrix} \dot{V}_1 \\ \dot{V}_2 \end{pmatrix}; \quad (7.8.6)$$

$$\Phi = M(\dot{V}V^{*T}) = M \begin{pmatrix} |V_1|^2 & V_1 V_2^* \\ V_1^* V_2 & |V_2|^2 \end{pmatrix} = \begin{pmatrix} \sigma_c^2 + \sigma_u^2 & \sigma_c^2 \rho^* \\ \sigma_c^2 \rho & \sigma_c^2 + \sigma_u^2 \end{pmatrix}, \quad (7.8.7)$$

где 
$$\rho = \exp\left(-j\frac{4\pi}{\lambda R}hL\right).$$

После подстановки (6) и (7) в (5), получаем:

$$W\left(\frac{h}{\dot{V}_1, \dot{V}_2}\right) = \frac{1}{2\pi\sqrt{2\sigma_c^2\sigma_u^2 + \sigma_u^4}} \exp\left\{-\frac{1}{2} \frac{(\sigma_c^2 + \sigma_u^2) \left[|V_1|^2 + |V_2|^2 - \sigma_c^2 (\dot{V}_1 V_2^* \rho + V_1^* V_2 \rho)\right]}{2\sigma_c^2\sigma_u^2 + \sigma_u^4}\right\}. \quad (7.8.8)$$

Для отыскания оптимального решения рассмотрим слагаемое в показателе, зависящее от  $\rho$ :

$$\begin{aligned} \dot{V}_1 V_2^* \rho + V_1^* V_2 \rho &= 2 \operatorname{Re} V_1^* V_2 \rho = 2 \operatorname{Re} V_1^* V_2 \exp\left(-j\frac{4\pi}{\lambda R}hL\right) = \\ &= \operatorname{Re} \left\{ V_1^* V_2 \left( \cos \frac{4\pi}{\lambda R}hL + j \sin \frac{4\pi}{\lambda R}hL \right) \right\} = \\ &= \operatorname{Re} V_1^* V_2 \cos \frac{4\pi}{\lambda R}hL - \operatorname{Im} V_1^* V_2 \cos \frac{4\pi}{\lambda R}hL. \end{aligned} \quad (7.8.9)$$

Дифференцируя по  $h$  и приравнявая результат к 0, получаем выражение:

$$\operatorname{tg} \frac{4\pi}{\lambda R}hL = \frac{\operatorname{Im} V_1^* V_2}{\operatorname{Re} V_1^* V_2}. \quad (7.8.10)$$



Отсюда следует, что оптимальная оценка высоты данной точки поверхности определяется из выражения:

$$\hat{h} = \frac{\lambda R}{4\pi L} \arg \operatorname{tg} \frac{\operatorname{Im} V_1^* V_2}{\operatorname{Re} V_1^* V_2}.$$

Нетрудно проверить, что мы действительно получаем несмещённую асимптотически эффективную оценку высоты отдельной точки поверхности. Структурная схема алгоритма обработки показана на рис. 7.23.




Рис. 7.23. Блок схема алгоритма оценки высоты элемента поверхности

## 7.9. Литература к главе 7

1. Большаков И.А. Статистические проблемы выделения потока сигналов из шума / И.А. Большаков. М.: Сов. радио 1969. 464 с.
2. Доросинский Л.Г. Измерение общегрупповых параметров потока сигналов / Л.Г. Доросинский, С.П. Литвиненко, Л.Н. Шалимов // Естественные и технические науки № 4(54). М., 2011.
3. Прэтт У.К. Цифровая обработка изображений / У.К. Прэтт. М.: Мир, 982 с.
4. Денисов Д.А. Сегментация изображений на ЭВМ / Д.А. Денисов, В.А. Низовкин // Зарубежная радиоэлектроника. 1985. № 10. с. 5-30.
5. Розенфельд А. Сегментация и модели изображений / А. Розенфельд, Л.С. Де йвис. ТИИЭР. 1979. Т. 67. № 5. с. 9-39.
6. Джайн А.К. Успехи в области математических моделей для обработки изображений / А.К. Джайн. ТИИЭР. 1981. т. 69. № 5. с. 9-39.
7. Террайн Ч.У. Алгоритмы анализа изображений, основанные на статистических моделях / Ч.У. Террайн, Т.Ф. Куатьери, Д.Е. Даржон. ТИИЭР. 1986. т. 72. № 4. с. 4-26.
8. Методы сегментации изображений / под ред. П.А. Бакута, В.Г. Лабунца. Тематический обзор. ч. 1. Изд-во УПИ им. С.М. Кирова. 1986. 127 с.

9. Бакут П.А. Сегментация изображений: методы выделения границ областей / П.А. Бакут, Г.С. Колмогоров // Зарубежная радиоэлектроника. 1987. № 10. с. 25-47.
10. A surweg thresholding techniques / Sahoo P.K., Soltani S., Wong A.K.S., Cher Y.C.// Comput Vision, Graphics and Image Processing. 1988. 41. № 2. p. 233-260.
11. Kundi Amlan, Mitza Sanjwet K. A new algorithm for image edge extraction using a statistical classifier approach // IEEE Trans.Pattern Anal, and Mach. Lntell 1987. т. 9. № 4. p. 569-577.
12. Wang Davig L. Knowledge based object detection us images // ICASSP – 87, Proc. Int. Conf. Acoust., Speech and Signal Process., Dallas, Tex., Apr. 6-9., 1987, vol. 1. New York. 1987. p. 269-272.
13. Доросинский Л.Г. Анализ адаптивного алгоритма обнаружения контуров на малококонтрастных радиолокационных изображениях / Л.Г. Доросинский, Т.М. Лысенко // Исследование земли из космоса. 1988. № 2. с.99-103
14. Доросинский Л.Г. Выбор метода совместного измерения угловых координат нескольких источников излучения / Л.Г.Доросинский. Радиотехника. 1987. № 11. с. 43-45.
15. Kobernichnko V.G. Sosnovsky A.V. Coherence estimation in interferometric SAR data processing. 24th International Crimean Conference Microwave & Telecommunication Technology, September 7-13, 2014, Sevastopol, Crimea, Russia, vol.2, pp. 1153-1154.
16. Sosnovsky A.V. A phase unwrapping algorithm for InSAR data processing. 24th International Crimean Conference Microwave & Telecommunication Technology, September 7-13, 2014, Sevastopol, Crimea, Russia, vol.2, pp. 1155-1156.
17. Dorosinskiy L.G. The research of the distributed objects' radar image recognition algorithms. Applied and Fundamental Studies. Proceedings of the 2st International Academic Conference. March 8-10, 2013, St. Louis, Missouri USA, vol. 1. pp. 211-214.
18. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА, формируемых в РСА монография – М.: Издательский дом Академии Естествознания, 2017. – 212 с.
19. Доросинский Л.Г., Трухин М.П. Приём и обработка сигналов от сложных целей: монография. – М.: Издательский дом Академии Естествознания, 2018. – 264 с.

---

## 8. АНАЛИЗ ЭФФЕКТИВНОСТИ АЛГОРИТМОВ ОБНАРУЖЕНИЯ ИЗМЕНЕНИЙ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ ПОВЕРХНОСТИ В МНОГОПОЗИЦИОННОЙ СИСТЕМЕ КОСМИЧЕСКОГО МОНИТОРИНГА

Проблема обнаружения, оценки параметров и классификации сигналов от пространственно-распределённых целей (ПРЦ), эффективная поверхность рассеяния (ЭПР) которых мало отличается от ЭПР подстилающей поверхности, была и остаётся одной из основных при разработке и создании современных радиолокационных систем мониторинга наземной и надводной обстановки современными и перспективными радиолокационными средствами [7, 10].

Задача обнаружения и классификации слабых сигналов на фоне мощных помех с помощью традиционных средств наблюдения, зачастую, не может быть решена с требуемой эффективностью. Дело в том, что большие спутники позволяют получить радиолокационное изображение (РЛИ) одного и того же участка поверхности с разнесением по времени как минимум, в несколько часов, а реально — в несколько суток. Такое временное различие не позволяет получить достаточное количество РЛИ для принятия статистически достоверных решений о наличии/отсутствии изменений радиолокационных изображений. Обнаружение названных отличий является основанием для принятия важных производственных, экологических, социальных и тому подобных решений в интересах самых разных отраслей народного хозяйства. Примерами могут служить задачи прогноза ледовой обстановки, прогноза и обнаружения чрезвычайных ситуаций: пожары, наводнения, оползни, сели и т. п., обнаружение не-санкционированных вырубок лесных участков, прогнозы урожайности сельскохозяйственных продуктов, анализ состояния морской поверхности и многие другие.

Рассмотрим ситуацию, когда необходимо принимать решение о принадлежности наблюдаемого РЛИ участка поверхности к одному из двух классов:

РЛИ наблюдаемого участка земной/водной поверхности не отличается от РЛИ при прежних наблюдениях — изменений нет — гипотеза  $H_1$ .

РЛИ того же участка содержит изменения, вызванные новыми физическими условиями (появление новых объектов, вырубка леса, сезонные изменения, изменения ледовой обстановки, половодье, наводнение и многое другое) — гипотеза  $H_2$ .

Исходными данными для принятия решения являются РЛИ, полученные несколькими космическими аппаратами: малыми или нано-спутниками. Задача алгоритма принятия решения заключается в том, чтобы с минимальной вероятностью ошибки определить наличие или отсутствие названных изменений. Поскольку на практике чаще всего реализуются ситуации, при которых изменение местности представлено сравнительно небольшим количеством элементов наблюдаемого сигнала на фоне поверхности с однородной ЭПР, необходимо установить границы применимости как аналитических выражений, так и метода статистического моделирования.

Поэтому основная цель данной главы — определить необходимое количество независимых «взглядов» на один и тот же участок поверхности (количество требуемых РЛИ) для надёжного (с заданной вероятностью ошибки) определения выбора типа

названной поверхности как аналитическими методами, так и методами статистического моделирования в зависимости от ряда параметров: размер поверхности, число независимых наблюдений (спутников), отношения мощностей отражаемых сигналов.

Примеры типовых радиолокационных изображений (РЛИ) приведены на рис. 8.1. В простейшем случае необходимо осуществить оптимальное различение двух гипотез, а именно: наблюдается поверхность типа 1 или 2, менее тривиальный случай заключается в том, чтобы установить, имеется ли на поверхности типа 1 участок, имеющий удельную ЭПР, характерную для поверхности 2. При этом космические аппараты (КА), на которых размещены радиолокаторы, двигаются по близко расположенным траекториям и наблюдают один и тот же участок поверхности [7, 10]. Далее считаем, что в группу малых спутников входит  $L$  идентичных КА.




Рис. 8.1. Примеры типовых РЛИ. Показаны области двух различных поверхностей

На первом этапе определим алгоритм классификации типа поверхности одним радиолокатором, которых двигается по своей траектории и облучает участки однородной поверхности так, что эти участки не пересекаются (рис. 8.2), что даёт основание считать принимаемые сигналы  $y_i(t)$ ,  $i = 1 \dots N$  ( $N$  – количество отсчетов) в отдельных точках траектории статистически независимыми. Наблюдаемые сигналы  $y_i$  поступают на устройство первичной обработки (УПО), на выходе которого формируется вектор  $\bar{z}(z_1, z_2, \dots, z_n)$ , отсчёты которого поступают в блок классификации.

Сигнал, отражённый от  $i$ -го участка наблюдаемой поверхности, представляет собой узкополосный нормальный случайный процесс, амплитуда и фаза которого практически неизменны в течение времени его наблюдения. Принимаемый сигнал наблюдается на фоне белого гауссовского шума. Таким образом, наблюдаемые данные имеют вид:

$$y_i(t) = A_i \cos(\omega_0 t + \psi_i) + \eta_i(t), \quad (8.1)$$

где  $A_i$ ,  $\psi_i$  – амплитуда и фаза сигнала, отражённого от  $i$ -го участка наблюдаемой поверхности, имеющие соответственно релеевское и равномерное распределения вероятностей [10],  $\eta_i(t)$  – белый гауссовский шум с нулевым математическим ожиданием  $\langle \eta_i(t) \rangle = 0$  и корреляционной функцией  $\langle \eta_i(t_1) \eta_i(t_2) \rangle = N_0 \delta(t_1 - t_2)$ , где  $N_0$  – спектральная плотность шума [2, 4].






Рис. 8.2. Схема формирования сигналов  $y_i(t)$  при движении радиолокатора

Для определения оптимального алгоритма предварительной обработки использован функционал правдоподобия при условии, что РЛС занимает  $i$ -е положение, то есть наблюдается сигнал  $y_i(t)$  [8] со следующей плотностью распределения:

$$\begin{aligned} \Delta(y) &= K \int_{A, \psi} W(y | A, \psi) W(A, \psi) dA d\psi = \\ &= K \int_{A, \psi} e^{-\frac{1}{N_0} \int_{\tau} [y(t) - A \cos(\omega_0 t + \psi)]^2} W(A, \psi) dA d\psi, \end{aligned} \quad (8.2)$$

где  $W(A, \psi)$  — плотности распределения наблюдаемых сигналов. Для нахождения плотности распределения итогового РЛИ выполним следующие преобразования:

$$\begin{aligned} x_{ci} &= A_i \cos \psi_i; \\ x_{si} &= A_i \sin \psi_i; \\ y_{ci} &= \frac{1}{T} \int y(t) \cos \omega_0 t dt; \\ y_{si} &= \frac{1}{T} \int y(t) \sin \omega_0 t dt; \\ z_i &= y_{ci}^2 + y_{si}^2. \end{aligned} \quad (8.3)$$

При выполнении выражений (8.3) можно показать, что плотность распределения величины  $z_i$  примет следующий вид:

$$\Delta(z_i) = \frac{1}{\sigma_i^2} e^{-\frac{z_i}{\sigma_i^2}}, \quad (8.4)$$

где  $\sigma_i$  — среднее квадратическое отклонение распределений исходных сигналов  $y_i(t)$ .

Отсюда следует, что достаточная статистика  $z_i$  представляет собой экспоненциальную случайную величину с параметром  $\sigma_i^2$ , при этом на данном этапе величина шума считается либо несущественной, либо учитывается на этапе выхода УПО в значении общей мощности.



### 8.1. Синтез алгоритма классификации

После первичной обработки наблюдаемый вектор  $z_i$  представляет собой последовательность независимых отсчётов, каждый из которых имеет экспоненциальное распределение вероятностей с параметром  $\sigma_i^2$ . Дальнейшая задача заключается в построении оптимального алгоритма различения двух гипотез  $H_1$  и  $H_2$ , отличающихся векторами параметров  $\sigma_1^2 = \{\sigma_{11}^2, \sigma_{12}^2, \dots, \sigma_{1N}^2\}$  и  $\sigma_2^2 = \{\sigma_{21}^2, \sigma_{22}^2, \dots, \sigma_{2N}^2\}$ . В основу алгоритма положено отношение максимального правдоподобия:

$$\Delta(\bar{z}) = \frac{\prod_{i=1}^N \frac{1}{\sigma_{2i}^2} e^{-\frac{z_i}{\sigma_{2i}^2}}}{\prod_{i=1}^N \frac{1}{\sigma_{1i}^2} e^{-\frac{z_i}{\sigma_{1i}^2}}} \geq q. \quad (8.5)$$

После логарифмирования выражение (8.5) приобретает следующий вид:

$$\ln \Delta(\bar{z}) = \sum_{i=1}^N \left( \frac{1}{\sigma_{1i}^2} - \frac{1}{\sigma_{2i}^2} \right) z_i \geq \ln q + \sum_{i=1}^N \ln \frac{\sigma_{1i}^2}{\sigma_{2i}^2}. \quad (8.6)$$

На первом этапе рассмотрена задача классификации двух типов поверхностей при условии, что  $\sigma_{11}^2 = \sigma_{12}^2 = \dots = \sigma_{1N}^2 = \sigma_1^2$  и  $\sigma_{21}^2 = \sigma_{22}^2 = \dots = \sigma_{2N}^2 = \sigma_2^2$ . В этом случае достаточная статистика  $l$ , иначе говоря, статистика, содержащая информацию, эквивалентную отношению правдоподобия, вычисляется простым суммированием отсчётов на выходе устройства первичной обработки. Для принятия решения  $l$  сравнивается с порогом, вычисляемым по априорным значениям дисперсий сигналов при одной и другой гипотезах:

$$l = \ln \Delta(\bar{z}) = \sum_{i=1}^N z_i \geq \frac{N\sigma_1^2\sigma_2^2}{\sigma_2^2 - \sigma_1^2} \sum_{i=1}^N \ln \frac{\sigma_1^2}{\sigma_2^2} = h. \quad (8.7)$$

Гипотезы на этом этапе считаем равновероятными и значение порога  $h$  равным единице. Эффективность алгоритма классификации может быть определена аналитически при достаточно большом числе отсчётов  $N$  (аппроксимация достаточной статистики нормальным распределением вероятностей) и/или методом статистического моделирования. В первом случае плотность вероятности статистики  $l$  аппроксимируется нормальным распределением:

$$W(l) = \frac{1}{\delta_k \sqrt{2\pi}} e^{-\frac{(l-m_k)^2}{2\delta_k^2}}, \quad k=1 \quad \text{при } \sigma_1^2, \quad k=2 \quad \text{при } \sigma_2^2. \quad (8.8)$$

Соответственно, параметры распределения (8.8) выражаются как  $M\{l\} = m_k = N\sigma_k^2$  и  $D\{l\} = \delta_k^2 = N\sigma_k^4$ . Общая вероятность ошибки при распознавании двух гипотез может быть рассчитана как сумма вероятности принять гипотезу  $H_2$  при истинной  $H_1$  и, соответственно, вероятности принять гипотезу  $H_1$  при истинной  $H_2$  следующим образом:

$$P_{\text{ош}} = P\{H_2 | H_1\} + P\{H_1 | H_2\} = 1 - \Phi\left(\frac{h - Nm_1}{\delta_1 \sqrt{N}}\right) + \Phi\left(\frac{h - Nm_2}{\delta_2 \sqrt{N}}\right), \quad (8.9)$$

где  $\Phi(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{x^2}{2}} dx$  – интеграл Лапласа.

Другим способом оценки качества распознавания может служить метод статистического моделирования. При большом числе отсчётов  $N$ , когда предположение о нормализации распределения достаточной статистики выполняется, расчёт, согласно формуле (8.9), даст достаточно точные результаты. В то же время при неравномерном распределении параметров выборочного распределения (наблюдении неоднородной поверхности) и сравнительно малом числе отсчётов метод статистического моделирования становится основным [5, 9].

Наблюдаемые данные модели представляют собой случайные величины с параметром  $\sigma_1^2$  или  $\sigma_2^2$ . Для каждого из двух случаев выполнено построение гистограммы и определены вероятности ошибок для каждого из возможных расположений порога. При изменении значения порога и определении вероятностей ошибок может быть найдено оптимальное положение порога и соответствующее ему значение ошибки. Блок-схема модели показана на рис. 8.3, алгоритм выбора порога — на рис. 8.4.



Рис. 8.3. Блок-схема статистического моделирования




Рис. 8.4. Алгоритм выбора оптимальной величины порога при статистическом моделировании

Приведем сравнительные результаты расчёта по формуле (8.9) и статистического моделирования. На рис. 8.5 показаны зависимости вероятностей ошибок распознавания двух гипотез (на примере двух типов поверхностей), рассчитанные по формуле (8.9) и полученные с применением статистического моделирования в зависимости от положения порога  $h$ . Количество отсчетов достаточных статистик  $N$  равно 100 (размеры модулируемых РЛИ  $10 \times 10$ ). Дисперсии входных данных в этом случае отличаются в два раза.




Рис. 8.5. Зависимость вероятности ошибки  $p$  от положения порога  $h$ .  
Число реализаций — 100000 для (а) и 1000 для (б) (линия 1 соответствует моделированию, линия 2 — расчёту по формуле (9))

На рис. 8.6 приведены выборочные гистограммы достаточных статистик. Гистограмма (1) построена при дисперсии отсчёта РЛИ, равной  $\sigma_1^2$ , гистограмма (2) —  $\sigma_2^2$ . Гистограммы построены на интервале от минимального значения данных с меньшей дисперсией до максимального значения набора данных с большей дисперсией, каждый подинтервал гистограммы получен делением общего интервала выборочных значений на число подинтервалов, определяемое в соответствии эмпирическим правилом Стёрджеса [3]:

$$k = 1 + [3,322 + \log B], \quad (8.10)$$

где  $B$  — количество реализаций модельных изображений.

Согласно расчетам по формуле (8.9), положение порога  $h$  при используемых входных данных равно 118,3, вероятность ошибки  $p$  при этом составляет 0,085. Аналогичные расчеты, выполненные с применением моделирования, дают значения  $h = 119,3$  и  $p = 0,096$  при числе реализаций, равном 100 тыс. и значения порога  $h = 120,3$  и  $p = 0,221$  для  $B = 1000$ . Очевидно, что необходимо установить границы применимости статистической модели, проанализировав значения вероятностей ошибок и положения порога при различных значениях входных параметров. Результаты представлены на рис. 8.7 и 8.8. Дисперсии отличаются в два раза, количество отсчетов равно  $N = 100$ .

Из графиков, представленных на рис. 8.7, следует, что при увеличении количества интервалов построения гистограммы вероятность ошибки и положение порогового значения стремится к расчётному значению. Это объясняется увеличением точности определения положения порога, в оптимальном случае погрешность определения порога не может быть меньше, чем минимальный размер дискрета оси значений

при построении гистограммы. Правило Стёрджеса, несмотря на широкую применимость при обработке многократных результатов измерений, в данном случае является не самым удачным, поскольку в этом случае шаг гистограммы содержит несколько значений случайной величины, что приводит к снижению точности определения порогового значения и соответствующего ему значения вероятности ошибки. При использовании числа интервалов более 200 вероятность, полученная с помощью моделирования, и расчётная вероятность отличаются не более, чем на 0,005, что обеспечивает достаточную точность. Дальнейший рост количества интервалов приводит к еще более высокой точности, однако существенно увеличивает время моделирования. Разумным компромиссом является выбор количества интервалов, равного  $2N$ , где  $N$  – количество отсчетов.




Рис. 8.6. Гистограммы распределения достаточных статистик  $l$  (число реализаций –  $B = 1000$ , количество отсчетов –  $N = 100$ . Вертикальной пунктирной линией показано значение порога, рассчитанного по формуле (8.9)




Рис. 8.7. Зависимость положения порога вероятности  $h$  (а) и ошибки  $p$  (б), рассчитанных с помощью моделирования, от количества разбиений интервала  $k$ . Пунктирной линией показан расчёт по формуле (8.9)

Из графиков, представленных на рис. 8.8, следует, что при числе реализаций, равном 50000, результаты моделирования практически совпадают с результатами, полученными на основании расчетов по формуле (8.9), при этом отклонения расчетных значений от полученных при моделировании составляют не более 0,003. При меньшем числе реализаций (менее 1000) имеют место большие расхождения с формулой, что обусловлено отклонением от нормального распределения достаточной статистики. Значения числа реализаций более 50 тыс., дают несущественный рост точности, но приводят к значительному увеличению времени моделирования.




Рис. 8.8. Зависимость вероятности ошибки  $p$  (а) и положения порога  $h$  (б), рассчитанных с помощью моделирования, от количества реализаций  $B$ . Пунктирной линией показан расчёт по формуле (8.9)

Таким образом, оптимальное количество шагов гистограммы при применении метода, основанного на моделировании ошибки классификации и положения порога, составляет удвоенное количество отсчетов, а число реализаций составляет  $B = 50000$ . Дальнейшее увеличение этих показателей приводит к незначительному улучшению точности.

Далее исследована точность результатов моделирования ошибки классификации и положения порога в зависимости от количества отсчетов  $N$ , изменяющегося в диапазоне от 4 до 900. Число реализаций выбрано равным 50 тыс., количество шагов гистограммы равно удвоенному количеству отсчетов. Результаты вычислений в сравнении с расчетами, выполненными согласно формуле (8.9), приведены на рис. 8.9.

Из графиков, приведенных на рис. 8.9, следует, что имеется расхождение величин порогов при расчёте и моделировании. Расхождение превышает величину шага гистограммы при количестве отсчетов более 600 и при дальнейшем росте  $N$  продолжает нарастать. Это объясняется неоднозначностью алгоритма определения положения порога при значительном количестве отсчетов: в этом случае центры распределений оказываются расположенными на значительном расстоянии друг от друга, и соответствующий минимум суммарной гистограммы растягивается на некоторый конечный интервал. Подобная ситуация приведена на гистограмме, показанной на рис. 8.10.






Рис. 8.9. Зависимость положения порога  $h$  (а) и вероятности ошибки  $p$  (б) от количества отсчетов  $N$ . Линия (1) – моделирование, линия (2) – расчёт

Из графика, приведенного на рис. 8.9, б видно, что имеется расхождение в расчете вероятности ошибки между формулой (8.9) и моделированием ошибки классификации и положения порога, напротив, для малых значений количества отсчетов. Это объясняется недостаточностью размера статистики при формировании вектора суммы  $z$ , что приводит к отклонению итогового распределения от нормального закона, соответственно, формула (8.9) является неприемлемой для такого случая. При этом теоретическое значение ошибки расходится с полученным при моделировании менее, чем на 5 % при количестве отсчетов более 64.




Рис. 8.10. Гистограммы распределения моделируемых статистик при количестве отсчетов  $N = 900$ . Линия (1) соответствует дисперсии  $\sigma_1^2$ , линия (2) –  $\sigma_2^2$ .

Количество реализаций – 5000, количество подынтервалов гистограммы – 1800

Далее выполнен анализ влияния отношения дисперсий на результаты моделирования и расчетов ошибки классификации и положения порога. Величина дисперсии  $\sigma_2^2$  изменялась в интервале от 1,5 до 16. Число реализаций – 50 тыс., количество отсчетов – 25, 100 и 400, количество шагов гистограммы положено равным удвоенному количеству отсчетов. Результаты приведены графиках, представленных на рис. 8.11, 8.12.

Из графиков, приведенных на рис. 8.11, следует, что при больших отношениях дисперсий значение порога, полученное с применением метода статистического моделирования, дает меньшее значение по сравнению с расчётным. При этом, чем больше количество отсчетов, тем при меньшем отношении дисперсий эффект становится более заметным. Это объясняется той же причиной, что и смещение порога при больших значениях отсчетов, а именно: при больших  $N$  средние значения распределений находятся на значительном удалении друг от друга, при этом на оси значений достаточной статистики образуется интервал, соответствующий нулевой вероятности ошибки (см. гистограммы на рис. 8.10).




Рис. 8.11. Зависимость положения порога  $h$  от соотношения дисперсий. Линия (1) соответствует количеству отсчетов  $N = 900$ , линия (2) –  $N = 100$ , линия (3) –  $N = 25$ .

Пунктиром показаны расчётные зависимости

В этом случае невозможно однозначно определить положение порога. Следует отметить, что при соотношении дисперсий 1/16 расхождение расчёта по формуле с моделированием составляет в среднем 6, тогда как общий диапазон значений приходится на интервал порядка 500, при количестве отсчетов 900 – расхождения составляет около 250 при общем диапазоне около 3300. Необходимо отметить, что данная ситуация соответствует случаю нулевых выборочных вероятностей ошибок (см. гистограммы на рис. 8.10), то выборки являются однозначно разделимыми, поэтому на корректность работы алгоритма указанный эффект не оказывает.




Рис. 8.12. Зависимость вероятности ошибки  $p$  от отношения дисперсий. Линия (1) соответствует количеству отсчетов  $N = 900$ , линия (2) —  $N = 100$ , линия (3) —  $N = 25$ . Серым цветом показаны расчётные зависимости

Из графиков, приведенных на рис. 8.12, следует, что с ростом отношения дисперсий величина ошибки уменьшается, что связано с естественным смещением средних значений выборок. При больших значениях числа отсчетов результаты расчетов и результаты моделирования находятся в достаточном соответствии. Для малых  $N$  имеется расхождение, обусловленное отклонением модельных данных от нормальных распределений. В этом случае формула (8.9) оказывается неприемлемой.

Таким образом, применение методов, основанных на моделировании ошибки классификации и порогового значения, полностью согласуется с расчётом по формуле (8.9) при значительном количестве отсчетов (более 64), рациональное количество реализаций составляет  $B = 5000$ , количество разбиений на интервале гистограммы должно быть равно удвоенной величине количества отсчетов. При моделировании, основанном на количестве отсчетов менее, чем 64, нарушается предположение о нормальности распределений достаточных статистик, что приводит к значительным ошибкам классификации. При большом отношении дисперсий (более 6 при количестве отсчетов, равном 100), а также при большом значении количества отсчетов наблюдается несоответствие модельных и расчетных значений, что обусловлено существенным расстоянием между средними значениями выборочных распределений. Однако эта ситуация соответствует нулевой вероятности ошибки разделения двух выборок, и как, следствие, хорошей итоговой разделимости гипотез.

## 8.2. Анализ эффективности классификации при комплексировании наблюдений разными спутниками

До сих пор все выводы касались принятия решения о типе поверхности одним КА. Для повышения эффективности классификации изменений на РЛИ в системе, состоящей из  $L$  малых спутников, следует использовать комплексирование данных от разных средств наблюдения. Рассмотрим зависимость вероятности правильного распознавания (ВПР) всей системы в целом ( $P_p$ ) от ВПР одного средства наблюдения ( $P$ ) при разном количестве источников информации  $L$ .

В простейшем случае вероятности  $P_\varepsilon$  и  $P$  связаны очевидным соотношением:

$$P_\varepsilon = 1 - P^L. \quad (8.11)$$

На рис. 8.13 приведена зависимость для алгоритма простого голосования. Из графика следует, что для получения итоговой вероятности правильного распознавания выше, чем 0,5, достаточно использовать пять КА с ВПР 0,2 либо семь спутников с ВПР 0,1. При ВПР 0,3 можно ограничиться тремя КА.

Результаты, представленные на рис. 8.13, использованы для оценки достаточного количества спутников при распознавании протяженных целей с ЭПР, соответствующими справочным данным (см. табл. 8.1) [8]. В табл. 8.2 приведены отношения дисперсий сигналов на выходе устройства первичной обработки, отражённых от какого-либо конкретного типа поверхности, по отношению к минимальной дисперсии, соответствующей сигналу от бетона.




Рис. 8.13. Вероятности правильного распознавания при комплексировании

Таблица 8.1

Справочные значения ЭПР

|                     | $\alpha = 10^\circ$        | $\alpha = 40^\circ$ | $\alpha = 70^\circ$ | $\alpha = 10^\circ$      | $\alpha = 40^\circ$ | $\alpha = 70^\circ$ |
|---------------------|----------------------------|---------------------|---------------------|--------------------------|---------------------|---------------------|
|                     | Горизонтальная поляризация |                     |                     | Вертикальная поляризация |                     |                     |
| Бетон               | −53                        | −38                 | −28                 | −45                      | −31                 | −28                 |
| Асфальт             | −47                        | −29                 | −24                 | −37                      | −23                 | −22                 |
| Пахотные земли      | −29                        | −20                 | −15                 | −25                      | −18                 | −16                 |
| Городская застройка | −20                        | −12                 | −8                  | −15                      | −11                 | −7                  |

Примечание.  $\alpha$  — угол между надиром и направлением на визируемый участок поверхности.

Рассмотрим влияние числа отсчётов сигнала  $N$  от поверхности на эффективность классификации. График зависимости пороговых значений количества отсчетов  $N_0$  от величины дисперсии, по достижении которых ошибка при моделировании имеет нулевое значение, приведен на рис. 8.14.

Таким образом, с ростом отношения дисперсий количество отсчетов, при котором ошибка определения принимает минимальное значение, уменьшается. Поэтому дальнейшие исследования выполнены для случая, когда количество отсчетов меньше величины  $N_0$ , поскольку в противном случае проблема классификации изменений на РЛИ не представляет интереса.




Рис. 8.14. График зависимости пороговой величины количества отсчетов  $N_0$  от отношения дисперсий (количество реализаций равно 50 тыс.), количество интервалов разбиения гистограммы равно удвоенному количеству отсчетов)

Таблица 8.2

### Нормированные ЭПР

|                     | $\alpha = 10^\circ$        | $\alpha = 40^\circ$ | $\alpha = 70^\circ$ | $\alpha = 10^\circ$      | $\alpha = 40^\circ$ | $\alpha = 70^\circ$ |
|---------------------|----------------------------|---------------------|---------------------|--------------------------|---------------------|---------------------|
|                     | Горизонтальная поляризация |                     |                     | Вертикальная поляризация |                     |                     |
| Асфальт             | 4,0                        | 7,9                 | 2,5                 | 6,3                      | 6,3                 | 4,0                 |
| Пахотные земли      | 250                        | 63                  | 20                  | 100                      | 20                  | 16                  |
| Городская застройка | 2000                       | 400                 | 100                 | 1000                     | 100                 | 130                 |

Рассмотрим зависимость вероятности ошибки (рис. 8.15) от соотношения дисперсий. Из графика, приведенного на рис. 8.15, следует, что с ростом угла между направлением надира и направлением на участок визируемой поверхности увеличивается вероятность ошибки, что связано с уменьшением отношения дисперсий между соседних классов объектов.

Из данных табл. 8.3 видно, что даже в случае малого отношения дисперсий элементов РЛИ для гарантированной классификации изменений на РЛИ можно ограничиться тремя или четырьмя спутниками, точное их количество определяется требованиями в конкретной задаче. В случае, когда относительная дисперсия превышает 10, для получения вероятности правильного распознавания 99 % достаточно использовать два спутника, при относительной дисперсии, равной 20, достаточно данных одного спутника.






Рис. 8.15. Зависимость вероятности ошибки  $\rho$  от отношения дисперсий. Пунктирными линиями показаны некоторые типовые значения соотношения дисперсий наблюдаемых объектов на фоне асфальта из данных, приведённых в табл. 8.2

В табл. 8.3 приведено минимальное количество спутников, необходимое для распознавания асфальта и пахотных земель с вероятностью от 80 % до 100 %. Количество отсчетов равно 16.

Таблица 8.3

## Необходимое число спутников

|                | $\alpha = 10^\circ$        | $\alpha = 40^\circ$ | $\alpha = 70^\circ$ | $\alpha = 10^\circ$      | $\alpha = 40^\circ$ | $\alpha = 70^\circ$ |
|----------------|----------------------------|---------------------|---------------------|--------------------------|---------------------|---------------------|
|                | Горизонтальная поляризация |                     |                     | Вертикальная поляризация |                     |                     |
| Асфальт        |                            |                     |                     |                          |                     |                     |
| 90 %           | 2                          | 1                   | 3                   | 2                        | 2                   | 2                   |
| 95 %           | 3                          | 2                   | 4                   | 3                        | 3                   | 3                   |
| 99 %           | 4                          | 2                   | 6                   | 3                        | 3                   | 4                   |
| 99,9 %         | 5                          | 3                   | 9                   | 4                        | 4                   | 5                   |
| 100 %          | 10                         | 6                   | 18                  | 7                        | 7                   | 10                  |
| Пахотные земли |                            |                     |                     |                          |                     |                     |
| 90 %           | 1                          | 1                   | 1                   | 1                        | 1                   | 1                   |
| 95 %           | 1                          | 1                   | 1                   | 1                        | 1                   | 1                   |
| 99 %           | 1                          | 1                   | 1                   | 1                        | 1                   | 2                   |
| 99,9 %         | 1                          | 1                   | 2                   | 1                        | 2                   | 2                   |
| 100 %          | 1                          | 2                   | 4                   | 2                        | 4                   | 4                   |

### 8.3. Классификация неоднородных РЛИ

Далее рассмотрен случай классификации двух РЛИ, одно из которых соответствует однородной поверхности (ЭПР вдоль наблюдаемого участка поверхности остаётся неизменной), а второе содержит внутри наблюдаемого участка элемент поверхности с отличающейся величиной ЭПР. Для этой задачи сформированы две последовательности отсчётов, в одной из которых дисперсия не меняется, во второй — содержит изменения (рис. 8.16).

Задача состоит в том, чтобы найти необходимые условия, при которых данные со скачком дисперсии будут различимы на фоне данных с однородной (априорно известной) дисперсией.




Рис. 8.16. Схема входных данных при моделировании скачка ЭПР.  
Дисперсия  $\sigma^2$  соответствует типичной ЭПР поверхности, величина  $\sigma_d^2$  — нетипичной

Рассмотрим влияние размера  $ds$  области нетипичной ЭПР на величину ошибки классификации. Соотношение дисперсий положено равным 20, количество отсчетов  $N$  менялось в интервале от 4 до 576, при этом максимальное значение  $ds$  не превышало корня из количества отсчетов. Результаты расчетов приведены в табл. 8.4.

Таблица 8.4

Размер области  $ds$

| $N/ds$ | 2    | 4    | 6    | 8    | 10   | 12   | 14   | 16   | 18   | 20   | 22   | 24   |
|--------|------|------|------|------|------|------|------|------|------|------|------|------|
| 4      | 0,50 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —    | —    |
| 16     | 0,50 | 0,49 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —    |
| 64     | 0,50 | 0,43 | 0,38 | 0,37 | —    | —    | —    | —    | —    | —    | —    | —    |
| 144    | 0,50 | 0,43 | 0,41 | 0,38 | 0,33 | 0,29 | —    | —    | —    | —    | —    | —    |
| 256    | 0,50 | 0,47 | 0,45 | 0,45 | 0,40 | 0,38 | 0,36 | 0,33 | —    | —    | —    | —    |
| 400    | 0,50 | 0,46 | 0,43 | 0,39 | 0,38 | 0,36 | 0,35 | 0,31 | 0,31 | 0,27 | —    | —    |
| 576    | 0,50 | 0,43 | 0,48 | 0,46 | 0,44 | 0,43 | 0,43 | 0,40 | 0,38 | 0,36 | 0,36 | 0,31 |

В том случае, когда участок нетипичной ЭПР состоит из одного отсчёта достаточной статистики (одного элемента разрешения), вероятность ошибки классификации нетипичной ЭПР близка к максимуму, т.е. к 50 %. В случае, если размер нетипичной

области ЭПР мал (менее 10 % от числа отсчётов) классификация возможна только при использовании не менее 100 отсчетов. График зависимости ошибки распознавания от количества отсчетов для различных соотношений размеров  $ds$  и  $N$  и приведен на рис. 8.18.




Рис. 8.17. График зависимости ошибки классификации  $p$  от количества отсчетов.

Линия (1) соответствует  $ds = \sqrt{N}$ , линия (2) —  $ds = \sqrt{N}/2$ , линия (3) —  $ds = \sqrt{N}/4$ , линия (4) —  $ds = \sqrt{N}/8$  (количество реализаций равно 1 млн., количество интервалов разбиения гистограммы равно удвоенному количеству отсчетов)




Рис. 8.18. Гистограммы распределения достаточных статистик моделируемых РЛИ при размере нетипичной области,  $N = 2$  отсчета (а) и  $N = 8$  отсчета (б). Общее количество отсчетов  $N = 64$ , количество реализаций равно  $B = 1$  млн., количество интервалов разбиения гистограммы равно удвоенному количеству отсчетов. Линия (1) соответствует входным данным с однородной дисперсией, линия (2) — данным с нетипичной областью

Таким образом, с ростом количества отсчетов  $N$  при фиксированном отношении  $ds/\sqrt{N}$  при количестве отсчетов свыше 400 точность практически не изменяется, то есть определяющим фактором при данных условиях является не количество отсчетов, а значение величины  $ds/\sqrt{N}$ , относительный размер нетипичной области ЭПР. В области малых значений  $N$  наблюдается незначительное увеличение вероятности ошибки (порядка 0,02), что связано с общим характером поведения данной

зависимости (рис. 8.11, б). В целом рост вероятности ошибки классификации связан с уменьшением размера области нетипичного поведения ЭПР: чем эта область больше, тем больше расхождение гистограмм соответствующих распределений, тем выше точность. Примеры гистограмм соответствующей ситуации приведены на рис. 8.18.

Следует заметить, что в случае близких гистограмм распределения входных данных, что имеет место при малом размере  $ds$ , оптимальное количество реализаций должно составлять на два порядка большую величину, то есть не менее 1 млн, поскольку в противном случае возрастает вероятность ошибок классификации изменений на РЛИ.

Рассмотрим влияние отличий в величине ЭПР на вероятность ошибки классификации. (Количество отсчетов – 64, моделирование выполнено для размеров области усреднения 8, 4 и 2, количество реализаций составляет  $10^6$ , количество интервалов разбиения гистограммы равно удвоенному количеству отсчетов  $N$ ). Результаты представлены на рис. 8.19. Ошибки классификации изменений на РЛИ, как и следовало ожидать, значительно выше, чем при однородных поверхностях.

Таким образом, даже для задач распознавания городской застройки на фоне бетона необходимо использовать данные нескольких наблюдений (спутников). Результаты расчетов для типовых соотношений дисперсий приведены в табл. 8.5.




Рис. 8.19. Зависимость вероятности ошибки  $p$  от отношения дисперсий.

Пунктирными линиями показаны некоторые типовые значения соотношения дисперсий наблюдаемых объектов на фоне асфальта из табл. 8.2

Из табл. 8.4 видно, что при размере области нетипичной ЭПР в два отсчета при использовании одного КА вероятность правильного распознавания едва ли превышает 50 %, однако при использовании даже двух КА вероятность правильного распознавания превышает 80 % даже для объектов с небольшим соотношением дисперсий (87,5 % при отношении дисперсий в 2,5). При использовании семи и более КА вероятность правильного распознавания превосходит 99 % для объектов с любым соотношением дисперсий.

Таблица 8.5

## Соотношения дисперсий

| $L$                        | $\alpha = 10^\circ$        | $\alpha = 40^\circ$ | $\alpha = 70^\circ$ | $\alpha = 10^\circ$      | $\alpha = 40^\circ$ | $\alpha = 70^\circ$ |
|----------------------------|----------------------------|---------------------|---------------------|--------------------------|---------------------|---------------------|
|                            | Горизонтальная поляризация |                     |                     | Вертикальная поляризация |                     |                     |
| <i>Асфальт</i>             |                            |                     |                     |                          |                     |                     |
| 1                          | 50,01 %                    | 50,50 %             | 50,00 %             | 50,23 %                  | 50,23 %             | 50,01 %             |
| 3                          | 87,50 %                    | 87,87 %             | 87,50 %             | 87,67 %                  | 87,67 %             | 87,50 %             |
| 5                          | 96,88 %                    | 97,03 %             | 96,88 %             | 96,95 %                  | 96,95 %             | 96,88 %             |
| 7                          | 99,22 %                    | 99,27 %             | 99,22 %             | 99,24 %                  | 99,24 %             | 99,22 %             |
| 9                          | 99,80 %                    | 99,82 %             | 99,80 %             | 99,81 %                  | 99,81 %             | 99,80 %             |
| <i>Пахотные земли</i>      |                            |                     |                     |                          |                     |                     |
| 1                          | 51,88 %                    | 51,58 %             | 51,13 %             | 51,76 %                  | 51,13 %             | 50,98 %             |
| 3                          | 88,86 %                    | 88,65 %             | 88,33 %             | 88,77 %                  | 88,33 %             | 88,22 %             |
| 5                          | 97,42 %                    | 97,34 %             | 97,21 %             | 97,39 %                  | 97,21 %             | 97,17 %             |
| 7                          | 99,40 %                    | 99,38 %             | 99,33 %             | 99,39 %                  | 99,33 %             | 99,32 %             |
| 9                          | 99,86 %                    | 99,85 %             | 99,84 %             | 99,86 %                  | 99,84 %             | 99,84 %             |
| <i>Городская застройка</i> |                            |                     |                     |                          |                     |                     |
| 1                          | 52,11 %                    | 52,02 %             | 51,76 %             | 52,04 %                  | 51,76 %             | 51,83 %             |
| 3                          | 89,02 %                    | 88,95 %             | 88,77 %             | 88,97 %                  | 88,77 %             | 88,82 %             |
| 5                          | 97,48 %                    | 97,46 %             | 97,39 %             | 97,46 %                  | 97,39 %             | 97,41 %             |
| 7                          | 99,42 %                    | 99,41 %             | 99,39 %             | 99,42 %                  | 99,39 %             | 99,40 %             |
| 9                          | 99,87 %                    | 99,87 %             | 99,86 %             | 99,87 %                  | 99,86 %             | 99,86 %             |

В данной главе проведён сравнительный анализ определения вероятностей ошибок классификации двух типов однородных поверхностей, соответствующим различным значениям ЭПР, аналитическим методом и методом статистического моделирования. В частности, показано, что расчетные данные имеют высокую корреляцию с модельными при использовании 100 и выше отсчетов, в противном случае расчеты по традиционным формульным приближениям дают некорректные результаты. Установлено, что оптимальное количество реализации при использовании модельных данных составляет  $B = 50$  тыс. в случае вероятности ошибки не выше 0,5, для более высоких значений ошибок рекомендуется увеличивать количество реализаций во избежание ложных распознаваний. Правило Стерджиса показало неудовлетворительные результаты при построении гистограмм модельных значений. Поэтому в решении настоящей задачи рекомендуется использовать количество разбиений, равное удвоенному количеству отсчетов.

Показано, что при комплексировании результатов, принятых решающими устройствами нескольких спутников, и отношении ЭПР различаемых поверхностей, превышающей величину, равную 10, для получения вероятности правильного распознавания в 99,9 % достаточно ограничиться двумя независимыми наблюдениями даже при использовании 16 отсчетов. При меньших отношениях ЭПР наблюдаемых объектов вероятность правильного распознавания может быть увеличена как за счет увеличения числа КА, так и за счет увеличения количества отсчетов.



При наличии на поверхности участка с нетипичной ЭПР, вероятность правильной классификации (обнаружения названной аномалии) существенно уменьшается. Тем не менее вероятность в 99 % может быть достигнута даже при малом размере аномалии (2 отсчёта) и отношении дисперсий 6,3, если комплексно использовать РЛИ, полученные с семи спутников.

#### **8.4. Литература к главе 8**

1. Богданович В.А., Вострецов А.Г. Теория устойчивого обнаружения, различения и оценивания сигналов. М.: Физматлит, 2003. — 320 с.
2. Ван Трис Г. Теория обнаружения, оценок и модуляции. М.: «Советское радио», 1972. — 744 с.
3. ГОСТ Р 8.736-2011 Государственная система обеспечения единства измерений (ГСИ). Измерения прямые многократные. Методы обработки результатов измерений. Основные положения. Федеральное агентство по техническому регулированию и метрологии. Москва Стенда ртинформ, 2013. — 28 с.
4. Доросинский Л.Г. Обнаружение сигналов в РСА на фоне мешающих отражений // Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Информатика. Телекоммуникации. Управление. 2009. № 5 (86). С. 168-173.
5. Доросинский Л.Г. Распознавание изображений, нейронные сети и генетические алгоритмы // Успехи современного естествознания. 2011. № 10. С. 87-88.
6. Dorosinskiy L.G. Invariants for the radar image classification // В сборнике: Applied and Fundamental Studies Proceedings of the 2nd International Academic Conference. Publishing House «Science and Innovation Center», and the International Journal of Advanced Studies. 2013. С. 214-216.
7. Dorosinskiy L.G., Kurganski A.A. Modeling the clutter reflection suppression algorithm in synthetic-aperture radar // В сборнике: CEUR Workshop Proceedings 3. Сер. «REIT-Spring 2018 – Proceedings of the 3rd International Workshop on Radio Electronics and Information Technologies» 2018. С. 49-57.
8. Dorosinskiy L., Myasnikov F. Radarsignal classification algorithms synthesis and analysis // В сборнике: Proceedings of 2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference, IAEAC 2017 2. 2017. С. 119-122.
9. Мясников Ф.С., Иванов О.Ю. Обнаружение изменений на земной поверхности по данным дистанционного зондирования // В сборнике: Компьютерный анализ изображений: Интеллектуальные решения в промышленных сетях (CAI-2016) сборник научных трудов по материалам I Международной конференции. Уральский федеральный университет имени первого Президента России Б.Н. Ельцина; Под общей редакцией А. Г. Тягунова. 2016. С. 161-162.
10. Сколник М.И. Справочник по радиолокации. Т.1. М.: «Техносфера», 2014. — 456 с.

## 9. ОСОБЕННОСТИ ПОЛУЧЕНИЯ РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ ДВИЖУЩИХСЯ ПРОСТРАНСТВЕННО-РАСПРЕДЕЛЕННЫХ ЦЕЛЕЙ

### 9.1. Искажение РЛИ при движении ПРЦ

Сложный характер движения пространственно-распределенной цели (ПРЦ) приводит к тому, что закон изменения фазы отраженного сигнала от каждого элемента цели и весовая функция обработки, призванная повторить этот закон при синтезе радиолокационного изображения (РЛИ), существенно отличаются, что, в свою очередь, приводит к искажениям, как радиолокационного изображения цели, формируемого в данном конкретном наблюдении, так и радиолокационного портрета ПРЦ, представляющего собой основу для формирования банка (базы) данных радиолокационных портретов (РП) ПРЦ. Возможные варианты таких искажений, вызванные движением цели в течение времени наблюдения, рассмотрены в данной работе.

Введем модель сигнала, принимаемого РЛС. Будем считать радиолокационные станции, входящие в систему наблюдения, в общем случае бистатическими<sup>25</sup>. Принимаемый отраженный сигнал представим в виде вектора комплексных амплитуд  $\bar{U}(t)$ , для составляющих которого справедливо выражение:

$$\begin{aligned} \bar{U}(t) = & U_k \int_{\Omega_k} f_k(\bar{x}) \frac{g_1(\bar{x}, t) g_2(\bar{x}, t)}{r_1(\bar{x}, t) r_2(\bar{x}, t)} S \left\{ t - [r_1(\bar{x}, t) + r_2(\bar{x}, t)]/c \right\} \times \\ & \times \exp \left\{ -jk[r_1(\bar{x}, t) + r_2(\bar{x}, t)] \right\} d\bar{x} + N(t). \end{aligned}$$

В приведенном выражении  $g_1(\bar{x}, t)$ ,  $g_2(\bar{x}, t)$  — значения нормированных диаграмм направленности передающей и приемной антенн РЛС в направлении точки цели  $\bar{x}$  в момент времени  $t$ ;  $r_1(\bar{x}, t)$ ,  $r_2(\bar{x}, t)$  — текущее значение дальности от передатчика и приемника РЛС до точки  $\bar{x}$  цели;  $s(t)$  — комплексная амплитуда модулирующей функции зондирующего сигнала, которую в дальнейшем считаем импульсной с длительностью импульса  $\tau$  и периодом повторения  $T$  и нормированной таким образом, что выполняется условие:

$$\frac{1}{\tau} \int |s(t)|^2 dt = 1,$$

где  $N(t)$  — комплексная амплитуда аддитивного шума радиолокационного тракта;  
 $k = \frac{2\pi}{\lambda}$  — волновое число.

Время наблюдения цели ограничено и равно  $T$ .

Введем обозначения, где

$$G(\bar{x}, t) = \frac{g_1(\bar{x}, t) g_2(\bar{x}, t)}{r_1(\bar{x}, t) r_2(\bar{x}, t)};$$

<sup>25</sup> Передатчик и приемник размещены на разных носителях.

$$S(\bar{x}, t) = s \left\{ t - \left[ r_1(\bar{x}, t) + r_2(\bar{x}, t) \right] / c \right\};$$

$$E(\bar{x}, t) = \exp \left\{ -Jk \left[ r_1(\bar{x}, t) + r_2(\bar{x}, t) \right] \right\}$$

и определим функцию неопределенности траекторного сигнала при формировании РЛИ ПРЦ:

$$\varphi(\bar{\rho}_x, \bar{\rho}_z) = \int E^* \left( \bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi} \right) S^* \left( \bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi} \right) G \left( \bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi} \right) \cdot G(\bar{\rho}_z, t) S(\bar{\rho}_z, t) E(\bar{\rho}_z, t) dt, \quad (9.1)$$

где  $E(\bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi})$ ,  $S(\bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi})$ ,  $G(\bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi})$  – матрицы, описывающие ожидаемый траекторный сигнал от точки цели, положение которой относительно центра НК в основной системе координат характеризуется вектором  $\bar{\rho}_x$ ;  $E(\bar{\rho}_z, t)$ ,  $S(\bar{\rho}_z, t)$ ,  $G(\bar{\rho}_z, t)$  – матрицы, задающие принимаемый траекторный сигнал от точки с координатой  $\bar{\rho}_z$ . Использование функции неопределенности в виде (9.1) позволяет не только определить свойства РЛИ при оптимальном его построении (то есть при полностью известных законах движения как ПРЦ, так и носителя РСА), но и оценить возможные искажения изображения цели, вызванные априорной неопределенностью относительно параметров взаимного перемещения НК и РСА.

При использовании импульсного сигнала

$$S(t) = \sum_{n=-N}^{N_p} S(t - nT), \quad (9.2)$$

где  $(2N + 1)$  – общее число импульсов, отраженных от цели, и предположении о неизменности за время, равное длительности импульса, следующих функций:

$$E(\bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi}) = \text{const}; \quad E(\bar{\rho}_z, t) = \text{const};$$

$$G(\bar{\rho}_z, t / \bar{\chi}^0, \bar{\chi}) = \text{const}; \quad G(\bar{\rho}_z, t) = \text{const}$$

получим:

$$\begin{aligned} \varphi(\bar{\rho}_x, \bar{\rho}_z) = & \sum_{n=-N}^N \sum_{m=-N}^N E^* \left( \bar{\rho}_x, t_n / \bar{\chi}^0, \bar{\chi} \right) E(\bar{\rho}_z, t_m) \times \\ & \times G(\bar{\rho}_x, t_n / \bar{\chi}^0, \bar{\chi}) G(\bar{\rho}_z, t_m) \times \\ & \times \int_0^* \left[ t - nT \frac{r_1(\bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi}) + r_2(\bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi})}{C} \right] \times \\ & S_0 \left[ t - mT \frac{r_1(\bar{\rho}_z, t / \bar{\chi}^0, \bar{\chi}) + r_2(\bar{\rho}_z, t / \bar{\chi}^0, \bar{\chi})}{C} \right] dt, \end{aligned} \quad (9.3)$$

$$\text{где} \quad t_n = t_{0p} + nT; \quad (9.4)$$

$r_1(\bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi})$ ;  $r_2(\bar{\rho}_x, t / \bar{\chi}^0, \bar{\chi})$  – ожидаемые законы изменения расстояний от точки, задаваемой радиусом–вектором  $\bar{\rho}_x$ , до передающей и приемной РЛС соответственно,  $r_1(\bar{\rho}_z, t)$ ,  $r_2(\bar{\rho}_z, t)$  – истинные законы изменения расстояний от точки  $\bar{\rho}_z$  до передающей и приемной РЛС.

Поскольку значение периода повторения  $T$  выбирается с учетом условия одно-значного измерения дальности в пределах зоны обзора, интеграл в (9.3) обращается в нуль для неравных значений  $n$  и  $m$ . Следовательно:

$$\begin{aligned} \varphi(\bar{\rho}_x, \bar{\rho}_z) = \sum_{n=-N}^N G(\bar{\rho}_x, t_n / \bar{x}^0, \bar{x}) G(\bar{\rho}_z, t_n) \times \\ \times E^*(\bar{\rho}_x, t_n / \bar{x}^0, \bar{x}) E(\bar{\rho}_z, t_n) \varphi_n^D(\bar{\rho}_x, \bar{\rho}_z), \end{aligned} \quad (9.5)$$

$$\begin{aligned} \varphi_n^D(\bar{\rho}_x, \bar{\rho}_z) = \int S_0 \left[ t - nT - \frac{r_1(\bar{\rho}_z, t) + r_2(\bar{\rho}_z, t)}{C} \right] \times \\ \times S_0^* \left[ t - nT - \frac{r_1(\bar{\rho}_x, t / \bar{x}^0, \bar{x}) + r_2(\bar{\rho}_x, t / \bar{x}^0, \bar{x})}{C} \right] dt \end{aligned} \quad (9.6)$$

где

— функция неопределенности одиночного зондирующего импульса. Поскольку РЛИ формируется только в окрестности цели, размеры которой существенно меньше любой из дальностей  $r_1(\rho, t)$  и  $r_2(\rho, t)$ , выражение (9.5) можно упростить, полагая

$$G(\bar{\rho}, t_n / \bar{x}^0, \bar{x}) = G(\bar{\rho}, t_n) = \frac{g_1(t_n) g_2(t_n)}{r_1^0(t_n) r_2^0(t_n)}, \quad (9.7)$$

где  $g_1(t_n)$  и  $g_2(t_n)$  — значения нормированных ДН передающей и приемной антенн в направлении на центр цели в момент излучения  $n$ -го импульса.  $r_1^0(t_n)$  и  $r_2^0(t_n)$  — дальности от передатчика и приемника до центра цели. С учетом (7) выражение (5) может быть представлено в виде:

$$\begin{aligned} \varphi(\bar{\rho}_x, \bar{\rho}_z) = \sum_{n=-M}^M \left[ \frac{g_1(t_n) g_2(t_n)}{r_1^0(t_n) r_2^0(t_n)} \right]^2 \times \\ \times \exp \left\{ Jk \left[ r_1(\bar{\rho}_x, t_n / \bar{x}^0, \bar{x}) + r_2(\bar{\rho}_x, t_n / \bar{x}^0, \bar{x}) - r_1(\bar{\rho}_z, t_n) - r_2(\bar{\rho}_z, t_n) \right] \right\} \varphi_n(\bar{\rho}_x, \bar{\rho}_z). \end{aligned} \quad (9.8)$$

Дополнительного упрощения можно достичь, предполагая сомножители  $\frac{g_1(t_n) g_2(t_n)}{r_1^0(t_n) r_2^0(t_n)}$  и  $\varphi_n^D(\bar{\rho}_x, \bar{\rho}_z)$  не зависящими от  $n$ , что соответствует случаю наблюдения

НК на сравнительно коротком участке траектории, когда можно пренебречь кривизной каналов дальности в окрестности цели и изменением значений нормированных ДН антенн РЛС в направлении на цель в процессе движения носителей РСА. При этом получим:

$$\varphi(\bar{\rho}_x, \bar{\rho}_z) = \left[ \frac{g_1(t_{0p}) g_2(t_{0p})}{r_{1p}^0(t_0) r_{2p}^0(t_0)} \right]^2 \varphi^D(\bar{\rho}_x, \bar{\rho}_z) \varphi^A(\bar{\rho}_x, \bar{\rho}_z), \quad (9.9)$$

$$\text{где } \varphi^A(\bar{\rho}_x, \bar{\rho}_z) = \sum_{n=-N}^M \exp \left\{ Jk_p \left[ r_1(\bar{\rho}_x, t_n / \bar{x}^0, \bar{x}) + r_2(\bar{\rho}_x, t_n / \bar{x}^0, \bar{x}) - r_1(\bar{\rho}_z, t_n) - r_2(\bar{\rho}_z, t_n) \right] \right\}. \quad (9.10)$$

Рассмотрим свойства функции (9.10), входящей в выражение для функции неопределенности траекторного сигнала в виде независимого сомножителя.

$$\varphi_p^A(\bar{\rho}_x, \bar{\rho}_z) = \sum_{n=-M_p}^{M_p} \exp \left\{ Jk_p \left[ \alpha_{00}^p(\rho_x) - \beta_{00}^p(\rho_z) + \sum_{i=1}^3 (\alpha_{i0}^p - \beta_{i0}^p + \bar{\alpha}_{i1}^p \bar{\rho}_x - \bar{\beta}_{i1}^p \bar{\rho}_z) (nT_p)^i \right] \right\}. \quad (9.11)$$

В последнем выражении  $\alpha$  соответствуют ожидаемому, а параметры  $\beta$  – реальному закону изменения дальности.

Анализ выражения (9.11) в первом приближении проведем с учетом следующих ограничений:

$$\alpha_{20}^p = \beta_{20}^p; \quad \alpha_{30}^p = \beta_{30}^p; \quad (9.12)$$

$$\bar{\alpha}_{21}^p = \bar{\beta}_{21}^p = 0; \quad \bar{\alpha}_{31}^p = \bar{\beta}_{31}^p = 0. \quad (9.13)$$

Использование допущений (9.12) и (9.13) позволяет рассматривать функцию (9.11), как сумму членов геометрической прогрессии. Эта сумма описывается следующим выражением:

$$\begin{aligned} \varphi^A(\bar{\rho}_x, \bar{\rho}_z) = & \exp \left\{ Jk \left[ \alpha_{00}(\bar{\rho}_x) - \beta_{00}(\bar{\rho}_z) \right] \right\} \times \\ & \times \frac{\sin \left[ k \left( \alpha_{10} - \beta_{10} + \bar{\alpha}_{11}\bar{\rho}_x - \bar{\beta}_{11}\bar{\rho}_z \right) T(2N+1)/2 \right]}{\sin \left[ k \left( \alpha_{10} - \beta_{10} + \bar{\alpha}_{11}\bar{\rho}_x - \bar{\beta}_{11}\bar{\rho}_z \right) T/2 \right]}. \end{aligned} \quad (9.14)$$

Предположим, что все параметры движения ПРЦ известны точно, то есть

$$\alpha_{10} = \beta_{10}; \quad \bar{\alpha}_{10} = \bar{\beta}_{10}. \quad (9.15)$$

Определим геометрическое место точек в пространстве координат изображения, для которых модуль (9.14) принимает наибольшее значение при отражении зондирующего сигнала от точки цели с координатой  $\bar{\rho}_z$ . Для этого необходимо решить относительно  $\bar{\rho}_x$  уравнение

$$\bar{\alpha}_{11}(\bar{\rho}_x - \bar{\rho}_z) - 1 \frac{\lambda}{T} = 0; \quad 1 = 0, \pm 1, \pm 2... \quad (9.16)$$

Это уравнение описывает в координатах изображения совокупность плоскостей, перпендикулярных вектору  $\bar{\alpha}_{11}$ . При  $1 = 0$  имеем уравнение плоскости, проходящей через точку с координатами  $\bar{\rho}_x = \bar{\rho}_z$  и удаленной от начала системы координат на расстояние

$$D(0) = \frac{\bar{\alpha}_{11}}{|\bar{\alpha}_{11}|} \bar{\rho}_z. \quad (9.17)$$

Расстояние от начала координат до 1-й плоскости составляет

$$D_1(1) = \frac{\bar{\alpha}_{11}}{|\bar{\alpha}_{11}|} \bar{\rho}_z + 1 \frac{\lambda}{T_p |\bar{\alpha}_{11}|}, \quad (9.18)$$

а расстояние между соседними плоскостями –

$$D_2 = \frac{\lambda}{T_p |\bar{\alpha}_{11}|}. \quad (9.19)$$

Для нахождения нулей функции (14) следует решить уравнение

$$\bar{\alpha}_{11}(\bar{\rho}_x - \bar{\rho}_z) - m \frac{\lambda}{T(2M+1)} = 0, \quad m = \pm 1, \pm 2, ... \quad (9.20)$$

Решение этого уравнения также описывает совокупность плоскостей в пространстве координат РЛИ, перпендикулярных вектору  $\bar{\alpha}_{11}$ . Эти плоскости следуют друг



за другом чаще, чем плоскости, соответствующие максимумам (9.14). Удаление  $m$ -й плоскости от начала координат составляет

$$d(M) = \frac{\bar{\alpha}_{11}}{|\bar{\alpha}_{11}|} \bar{\rho}_x + m \frac{\lambda}{T(2M+1)|\bar{\alpha}_{11}|}. \quad (9.21)$$

При  $m = \pm 1$  получаем два первых нуля рассматриваемой функции и определим обеспечиваемое ею разрешение

$$\Delta_\alpha^0 = D_0(1) - D_0(-1) = \frac{2\lambda}{T(2M+1)|\bar{\alpha}_{11}|}. \quad (9.22)$$

Таким образом, выражение (9.14) в пространстве изображений является функцией только одной координаты, измеряемой в направлении вектора  $\bar{\alpha}_{11}$ . Разрешающая способность в этом направлении определяется в соответствии с (9.22). Для однопозиционной РЛС при отсутствии собственного движения цели ( $\bar{V}_{0p} = 0, \bar{\omega}_p = 0$ ) имеем:

$$\bar{\alpha}_{11} = -\frac{2\bar{V}_1}{|\bar{r}_{0p}(t_0) - \bar{r}_{1p}(t_0)|}. \quad (9.23)$$

Такая РЛС в направлении путевой скорости обеспечивает разрешение

$$\Delta = \frac{\lambda}{|\bar{V}_1| T(2M+1)} |\bar{r}_0(t_0) - \bar{r}_1(t_0)|. \quad (9.24)$$

В дальнейшем, в соответствии с терминологией, принятой при описании РЛС с синтезированной апертурой направление, задаваемое вектором  $\bar{\alpha}_{11}$  будем именовать азимутальным. Примерный вид зависимости модуля (14) от азимутальной координаты показан на рис. 9.1.




Рис. 9.1. Азимутальное сечение модуля функции неопределённости

Используя (9.20) и (9.23) совместно с данными конкретной РЛС, например, типа SEASAT, нетрудно сделать вывод о том, что расстояние между пиками (9.14) во много раз превышает размеры существующих ПРЦ. Поэтому в дальнейшем ограничимся рассмотрением функции  $\varphi^A(\rho_x, \rho_z)$  только в окрестности главного максимума, положение которого задается выражением (9.17).

При отсутствии точных данных о движении цели равенства (9.15) не соблюдаются. В этом случае положение максимума модуля функции (9.14) определяется уравнением

$$\bar{\alpha}_{11}\bar{\rho}_x - \bar{\beta}_{11}\bar{\rho}_z + \alpha_{10} - \beta_{10} = 0, \quad (9.25)$$

которое по-прежнему описывает плоскость, перпендикулярную вектору  $\bar{\alpha}_{11}$ . Однако, удаление ее от начала координат зависит не только от положения отражающей точки цели (вектор  $\bar{\rho}_z$ ), но и от величины и ориентации вектора  $\bar{\beta}_{11}$  и разности  $(\alpha_{10} - \beta_{10})$ :

$$D(0) = \frac{\bar{\beta}_{11}}{|\bar{\alpha}_{11}|} \bar{\rho}_z - \frac{\alpha_{10} - \beta_{10}}{|\bar{\alpha}_{11}|}. \quad (9.26)$$

При этом разрешение в азимутальном направлении по-прежнему задается выражением (9.22). Анализ (9.26) позволяет описать искажения РЛИ, которые возникают в тех случаях, когда априорные сведения о собственном движении цели не соответствуют действительности.

Предположим, что

$$\bar{\alpha}_{11} = \bar{\beta}_{11}; \quad \alpha_{10} = \beta_{10}. \quad (9.27)$$

Как следует из (9.26), все изображение цели сдвинется вдоль азимутальной оси на величину  $(\beta_{10} - \alpha_{10})/|\bar{\alpha}_{11}|$ . Допустим, что вектор  $\bar{\beta}_{11}$  отличается от  $\bar{\alpha}_{11}$  только постоянным множителем, то есть

$$\bar{\beta}_{11} = b\bar{\alpha}_{11}; \quad \alpha_{10} = \beta_{10}. \quad (9.28)$$

Из (9.26) следует, что азимутальная координата отклика от каждой точки на изображении изменится в « $b$ » раз. Это приводит к сжатию ( $b < 1$ ) или растяжению ( $b > 1$ ) изображения цели по азимуту. Но такое изменение РЛИ не эквивалентно изменению масштаба по оси азимута, так как расстояние между первыми нулями функции  $\varphi^A$  (14) не изменяется. В связи с этим для многоточечных целей при  $b > 1$  возможно раздельное наблюдение откликов точек, не разрешаемых при  $b = 1$ . Наоборот, при  $b < 1$  возможна потеря разрешения за счет наложения откликов соседних точек друг на друга.

Если вектора  $\bar{\alpha}_{11}$  и  $\bar{\beta}_{11}$  при равенстве модулей отличаются ориентацией в пространстве, то положение отклика от точки на изображении определяется ее проекцией на направление вектора  $\bar{\beta}_{11}$ . Поэтому взаимное расположение откликов от отражающих точек цели на азимутальной оси при изменении собственного движения ПРЦ сложным образом меняется.

Выражение (9.14) описывают функцию только одной координаты, измеряемой в направлении вектора  $\bar{\alpha}_{11}$ . Общеизвестно, что функция неопределенности одиночного импульсного сигнала  $\Phi^A(\rho_x, \rho_z)$  обеспечивает разрешающую способность РЛС по наклонной дальности. Для бистатической РЛС направление, вдоль которого наблюдается наилучшее разрешение по дальности, определяется геометрической суммой единичных векторов визирования цели приемной и передающей РЛС.

$$E = \frac{\bar{E}_1 + \bar{E}_2}{|\bar{E}_1 + \bar{E}_2|}. \quad (9.29)$$

Таким образом, функция неопределенности траекторного сигнала является функцией двух координат на плоскости, отсчитываемых вдоль направления наклонной дальности, заданного (9.29), и вдоль азимутального направления, единичный вектор

которого равен  $\bar{\alpha}_{11}/|\bar{\alpha}_{11}|$ . Для удобства введем дополнительную систему координат  $0' V_1 V_2 V_3$ , центр которой совпадает с центром цели. Ось  $0' V_1$  ориентирована по направлению вектора  $\bar{\alpha}_{11}$ . Ось  $0' V_2$  совпадает с вектором визирования центра цели  $\bar{E}_{\varepsilon_p}$ , а ось  $0' V_3$  перпендикулярна двум другим осям и дополняет систему до правой декартовой. Отметим, что оси  $0' V_1$  и  $0' V_2$  в общем случае не ортогональны. При произвольном соотношении между модулями и направлениями векторов  $\bar{\alpha}_{11}$  и  $\bar{\beta}_{11}$  (9.26) можно представить в следующем виде:

$$D_1(0) = \frac{|\bar{\beta}_{11}|}{|\bar{\alpha}_{11}|} \left[ \frac{\bar{\beta}_{11}}{|\bar{\beta}_{11}|} \bar{p}_z - \frac{\alpha_{10} - \beta_{10}}{|\bar{\beta}_{11}|} \right]. \quad (9.30)$$

Выражение в квадратных скобках определяет азимутальное положение максимума отклика от точки  $\bar{p}_z$  цели на изображении для случая (9.27) с той лишь разницей, что в качестве азимутального используется направление вектора  $\bar{\beta}_{11}$ . Следовательно, изображение, получаемое в системе координат  $0' V_1 V_2 V_3$ , представляет собой масштабированное по азимутальной оси РЛИ, построенное в другой системе координат. Пространственная ориентация азимутальной оси этой системы координат в общем случае неизвестна.

На рис. 9.2 и 9.3 приведены примеры, иллюстрирующие рассмотренные искажения РЛИ. Предполагается, что цель состоит из трех отражающих точек, расположенных в одном канале дальности. На рис. 9.3а показано пространственное расположение точек цели в системе координат  $0' V_1 V_2 V_3$ . На последующих рисунках показаны азимутальные сечения модулей функции неопределенности (9) для каждой из точек цели при различных соотношениях между  $\bar{\alpha}_{11}$ ,  $\bar{\beta}_{11}$ ,  $\alpha_{10}$  и  $\beta_{10}$ .

Обратимся теперь к общему виду функции  $\Phi_p^A(\rho_x, \rho_z)$  (11) и кратко рассмотрим, как отражается на свойствах РЛИ несоблюдение условий (13). Невыполнение (12), как следует из (11) приводит к расфокусировке откликов всех отражающих точек на изображении. Кроме того, происходит снижение максимума главного лепестка отклика. Нарушение неравенства (13) вызывает дополнительную расфокусировку. В наибольшей степени ей подвержены изображения точек, удаленных от центра цели.

Из сказанного выше следует, что к числу основных видов искажений РЛИ относятся:

- смещение изображений вдоль азимутальной оси,
- снижение разрешающей способности за счет расфокусировки,
- изменение взаимного расположения откликов от «блестящих точек» цели на изображении из-за несоблюдения равенства

$$\bar{\alpha}_{11} = \bar{\beta}_{11}. \quad (9.31)$$

Первые два вида искажений достаточно хорошо известны [1, 2]. В ряде случаев удается найти способы уменьшения их влияния [2, 3]. Значительно более сложной представляется ситуация снижения третьего вида искажений. К нарушению условия (9.31) ведет незнание вектора собственной скорости цели относительно поверхности вектора угловой скорости вращения ПРЦ в момент ее наблюдения. Следовательно, собственное поступательное движение цели приводит к небольшим (порядка десятых долей процента) изменениям составляющих вектора  $\bar{\beta}_{11}$ . В то же время вращение ПРЦ может приводить к изменению компонент этого вектора в 10 и более раз. Таким образом, вращение цели является одним из самых существенных факторов, приводящих к искажению РЛИ.

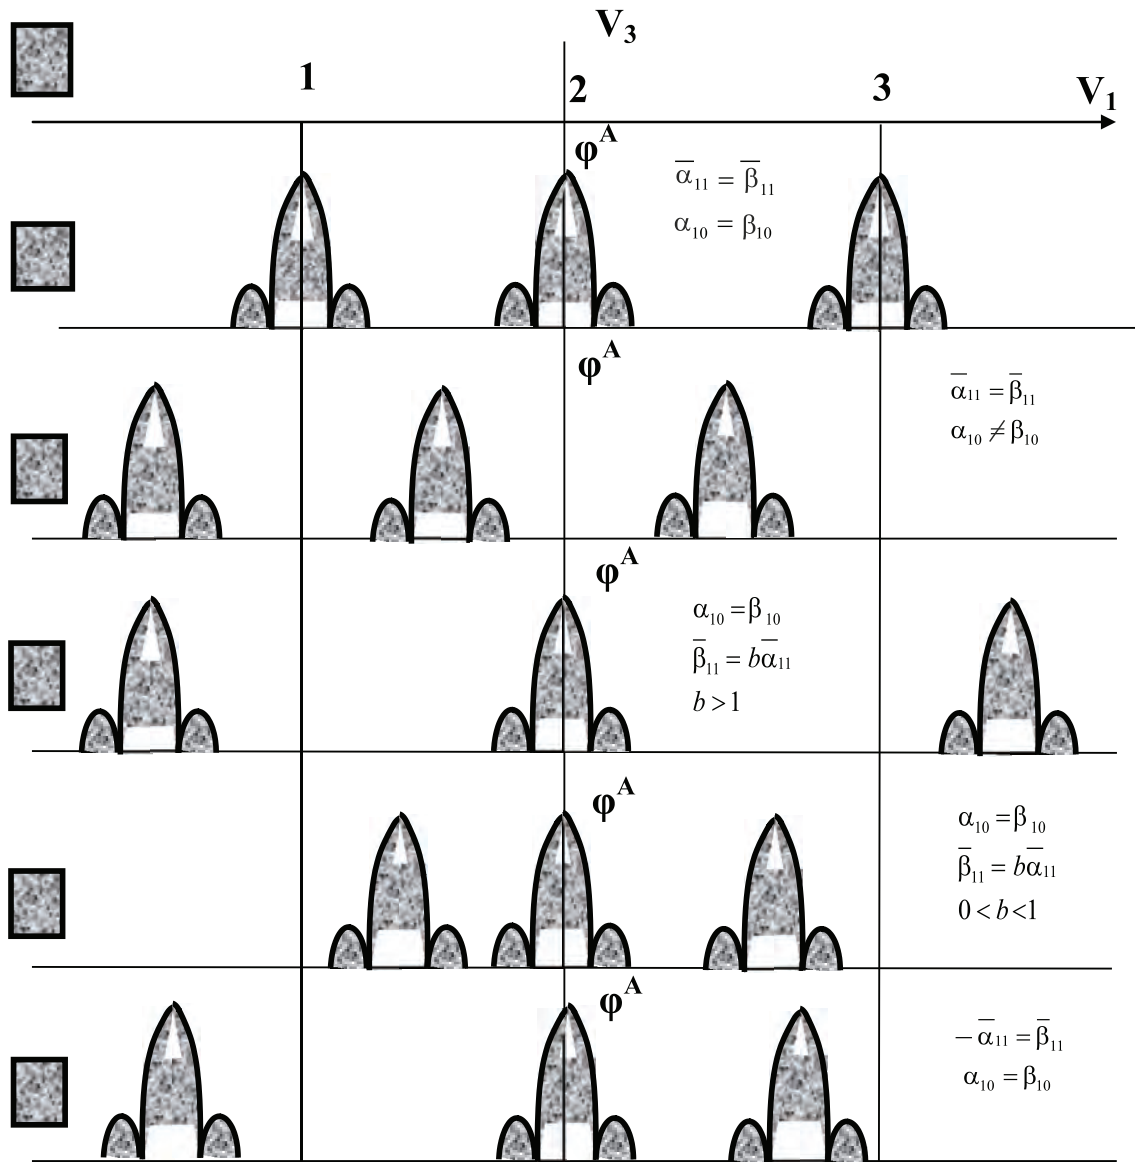


Рис. 9.2. Примеры искажений РЛИ

В тех случаях, когда в модели отражающих НК присутствуют «мнимые блестящие точки», искажения РЛИ при наличии известной угловой скорости вращения имеют более сложный характер. Это связано с тем, что при вращении цели движение этих точек существенно отличается от движения самой цели. «Мнимые» точки образуют как бы отдельное жесткое тело, вектор угловой скорости которого в основной системе координат имеет вид:

$$\bar{\omega} = \{-\omega_1, -\omega_2, -\omega_3\},$$

тогда как для самой цели

$$\bar{\omega} = \{\omega_1, \omega_2, \omega_3\}.$$

В результате вектор  $\bar{\beta}_{11}$  для «мнимых» точек может быть ориентирован в пространстве иначе, чем для остальной части цели. Итоговое изображение при этом представляет собой сумму двух РЛИ (самой цели и ее «мнимой» части), искаженных в равной степени.

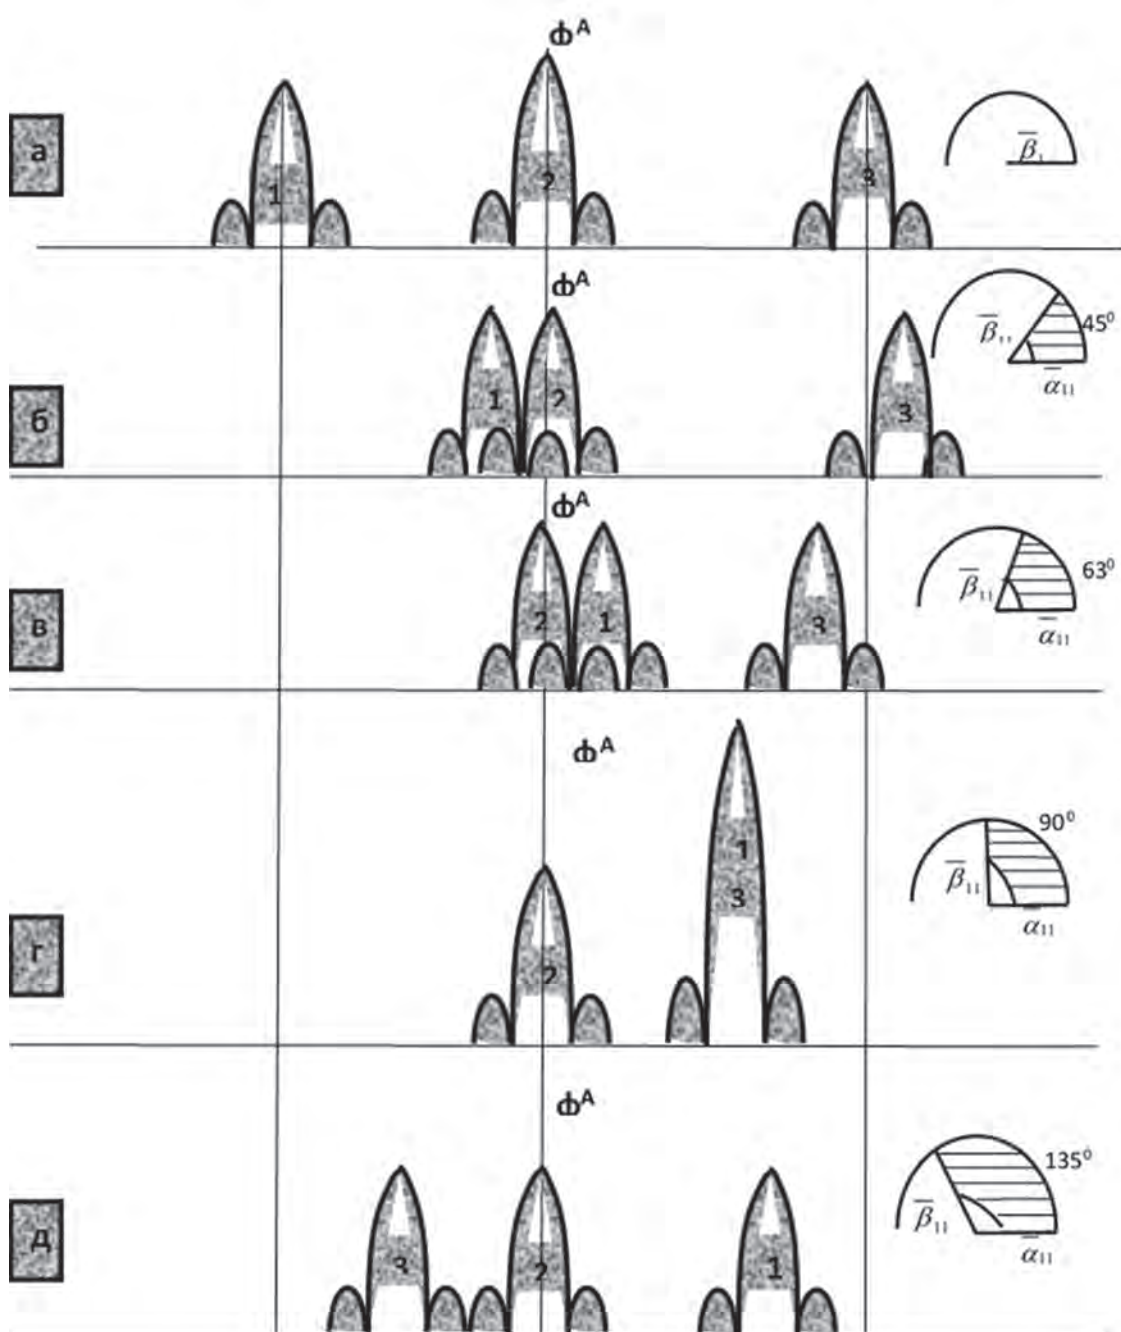


Рис. 9.3. Примеры искажений РЛИ при различной ориентации векторов ( $|\bar{\alpha}_{11}| = |\bar{\beta}_{11}|$ ,  $\bar{\alpha}_{10} = \bar{\beta}_{10}$ )

В качестве иллюстрации проведенного анализа свойств РЛИ ниже рассмотрены изображения, полученные путем моделирования на ЭВМ без учета аддитивного шума радиолокационного тракта. При этом использовалась гипотетическая модель цели, состоящая из 11 «блестящих» точек без диффузионной составляющей. Координаты точек в системе координат, оси которой параллельны осям системы  $0 X_1 X_2 X_3$ , приведены в табл. 9.1, а их пространственное положение показано на рис. 9.4. Точки с 8-й по 11-ую являются «мнимыми», о чем, в частности, свидетельствуют отрицательные значения высот (координата  $X_3$ ).



Таблица 9.1

Координаты точек ПРЦ

| Номер точки | $X_1$ (м) | $X_2$ (м) | $X_3$ (м) |
|-------------|-----------|-----------|-----------|
| 1           | 0         | 100       | 15        |
| 2           | 100       | 100       | 15        |
| 3           | -50       | 0         | 30        |
| 4           | 0         | 0         | 0         |
| 5           | 50        | 0         | 30        |
| 6           | -100      | -100      | 15        |
| 7           | 0         | -100      | 15        |
| 8           | 100       | 100       | -15       |
| 9           | 50        | 0         | -30       |
| 10          | -100      | -100      | -15       |
| 11          | 0         | -100      | -15       |




Рис. 9.4. Гипотетическая модель цели

На рис. 9.5 приведена изометрическая проекция модуля комплексного РЛИ описанной цели при отсутствии собственного движения. Изображение занимает девять каналов дальности, сигналы в которых предполагаются статистически независимыми. Отклики всех точек пронумерованы. Высота пролета составляет 1000 км, горизонтальная дальность до цели 500 км. Как и следовало ожидать, азимутальное положение «мнимых точек» совпадает с положением порождающих их «блестящих точек».




Рис. 9.5. РЛИ цели без вращения

На рис. 9.6 показано изображение той же цели при наличии вращения вокруг оси  $OX_1$  с угловой скоростью 10 мрад/с. При этом центральная точка цели своего положения не изменила. Остальные «блестящие точки» удалились от центра пропорционально своим истинным координатам. Смещение «мнимых точек» имеет противоположное направление. В результате этого структура изображения оказывается сильно искажена.




Рис. 9.6. РЛИ цели при вращении

## 9.2. Литература к главе 9

1. Радиолокационные станции обзора Земли / Г.С. Кондратенков, В.А. Потехин, А.П. Реутов, Ю.А. Феокистов; под ред. Г.С. Кондратенкова. М.: Радио и связь, 1983. 271 с.
2. Curlander J.C. WuC., Pang A. Automated preprocessing of spaceborne SAR data/ @Int. Geochi and remote Sens. Symp. (IGARSS'82) Munich, Juni 1-4, 1982, Dig Vol. 2". N.Y., 1982, FA1.3/1 FA 1/3/6&.
3. Wu K.H., Vant M.R. A SAR focusing technique for imaging targets with random motion. @Proc. IEEE Nat. Aerosp. and Electron. Conf. NAECON, Dayton, 21-25 May, 1984, vol. 1" York, N.Y., 1984 p. 289-295New.

## 10. ФИЛЬТРАЦИИ СПЕКЛ-ШУМА

Радиолокаторы с синтезированной апертурой (РСА) позволяют получать изображения земной поверхности и объектов, расположенных на ней, независимо от метеоусловий и естественной освещенности наблюдаемой сцены с разрешением в единицы метров. Однако изображения, полученные когерентными радиолокаторами, имеют достаточно специфические особенности, что накладывает свой отпечаток на их дальнейшую обработку [1–6]. Кроме того, некоторые из объектов радиолокационного наблюдения могут находиться в движении в момент съемки. Это приводит к дополнительным искажениям, что также необходимо учитывать при извлечении информации из радиолокационного изображения (РЛИ) [3, 5].

Пожалуй, основной отличительной особенностью когерентных радиолокационных изображений, в том числе и получаемых с помощью РСА, является наличие на них пятнистости. На рис. 10.1 приведены фрагменты изображений, полученные различными радиолокационными системами с синтезированной апертурой космического базирования в разные годы. На всех снимках отчетливо прослеживается характерная пятнистость, о которой говорилось выше, особенно отчетливо она заметна на однородных поверхностях.




Рис. 10.1. Примеры типовых РЛИ:  
а – Алмаз; б – *RadarSat-2*; в – *ALOS*; г – *NitrraSAR-X*

Пятнистость или спекл-шум можно рассматривать с двух позиций. Во-первых, как помеху [9, 10, 17, 18], во-вторых, как полезное явление, несущее информацию и о системе обработки РСА [19, 20], и о самой поверхности [8].

При решении большинства задач дистанционного зондирования Земли (ДЗЗ) спекл является нежелательным фактором, так как его наличие на изображениях существенно затрудняет их дешифрируемость (может привести к ложному обнаружению точечных целей, к пропуску слабоконтрастных объектов и т.д.) как человеком-оператором, так и в автоматическом режиме.

В рамках этого подхода разработаны методы снижения уровня спекл-шума, основанные на некогерентном суммировании независимых изображений, линейной фильтрации, нелинейном преобразовании и т.д.

Снижение уровня спекл-шума с помощью указанных методов, вместе с полезным эффектом, приводит к ухудшению ряда других характеристик РЛИ (снижению разрешения, размытию границ, подавлению точечных целей и т.д.). В связи с этим для исследования эффективности алгоритмов обработки РЛИ необходимо иметь, с одной стороны, объективные критерии качества РЛИ, а с другой стороны типовые (тестовые) фрагменты РЛИ, позволяющие наилучшим образом оценивать эти алгоритмы по указанным критериям.

Целью данной главы является уточнение математических моделей радиолокационных изображений типовых объектов, что необходимо для разработки алгоритмов цифровой обработки когерентных РЛИ. Кроме того, в главе представлен сравнительный анализ основных (наиболее часто используемых на практике) процедур фильтрации спекл-шума как на моделях, так и на реальных РЛИ.

### 10.1. Математическая модель и статистические характеристики когерентных РЛИ протяженных целей

Под протяженной целью здесь и далее рассматривается однородная шероховатая поверхность. Как известно [7–10], на РЛИ таких поверхностей, полученных в когерентных радиолокационных системах, наблюдается характерная пятнистость (спекл). Рассмотрим модель радиолокационных отражений от шероховатой поверхности (рис. 10.2).

Пусть элемент рассеивающей поверхности (протяженной цели), соответствующий элементу разрешения  $\delta\theta = \delta x \delta y$  расположен в области облучения диаграммы направленности антенны РЛС  $\Omega$ . Для описания отражающих свойств поверхности воспользуемся так называемой функцией радиолокационного рельефа (ФРР) [8]

$$\dot{\rho}(\theta, t) = \rho(\theta, t) \exp\{j\varphi(\theta, t)\}, \quad (10.1)$$

где  $\theta^T$  — вектор координат, образованный текущей путевой и наклонной дальностями.

Эта функция описывает зависимость от  $x$ ,  $y$  и  $t$  комплексной амплитуды электромагнитной волны, отраженной элементарным участком поверхности в сторону радиолокационной станции (РЛС) и нормированной к амплитуде падающей волны. В общем случае ФРР зависит от углов наблюдения, длины волны, поляризации зондирующего сигнала и т.д. [11].

Будем считать, что элемент поверхности  $\Delta\theta$  состоит из конечного, но большого числа независимых точечных отражателей. Поскольку взаимная ориентация и композиция этих отражателей могут меняться во времени, ФРР в общем случае флуктуирует. Вместе с этим, эти флуктуации на интервале синтеза являются медленными, так что для РСА можно считать  $\dot{\rho}(x, y, t) = \dot{\rho}(x, y)$ .






Рис. 10.2. Геометрические соотношения

В большинстве случаев, вследствие независимости отдельных точечных отражателей, ФРР представляет собой комплексное гауссовское случайное поле с нулевым математическим ожиданием, определяемое корреляционной функцией

$$R_p(\bar{\theta}_1, \bar{\theta}_2) = \rho(\bar{\theta}_1) \rho(\bar{\theta}_2). \quad (10.2)$$

Область высокой корреляции функции  $R_r$  соизмерима с длиной волны [12]. Вследствие малости этой области по сравнению с элементами разрешения  $\Delta\theta$ , флуктуации  $\dot{\rho}(\theta)$  можно считать  $\delta$  – коррелированными по пространству, то есть

$$R_p(\bar{\theta}_1, \bar{\theta}_2) = K_p(\bar{\theta}_1) \delta(\bar{\theta}_1 - \bar{\theta}_2). \quad (10.3)$$

Функция  $K_p(\theta)$ , называемая функцией рассеяния поверхности, является основной статистической характеристикой отражающих свойств поверхности [12].

Нормируя ФРР относительно СКО  $a(x, y) = \sqrt{K_p(x, y)}$ , приходим к представлению ее в виде мультипликативной модели

$$\rho(x,y) = a_o a(x,y) v(x,y), \quad (10.4)$$

где  $a_\Omega$  — средняя интенсивность отражений в области  $\Omega$ ;  $a(x,y)$  — функция, описывающая естественную изменчивость поверхности (местную отражающую способность);  $v(x,y)$  — однородное гауссовское случайное поле с единичной дисперсией, независимое от элемента к элементу разрешения, описывающее пятнистость (спекл-шум).

Таким образом, пятнистость на РЛИ обусловлена заложенным в самом сигнале множителем  $v(x, y)$ , т. е. моделью отражений в виде большого числа независимых отражателей.

Для определения статистических характеристик РЛИ представим процесс формирования его последовательностью пространственно-временных операторов.



Для распределенной цели с ФРП  $\dot{\rho}(x, y)$  отраженный сигнал в пределах области наблюдения  $\Omega$  представляет собой суперпозицию

$$\dot{S}(x, y) = \dot{\rho}(x, y) * \dot{g}(x, y), \quad (10.5)$$

где  $*$  — обозначение двумерной свертки;  $\dot{g}(x, y)$  — импульсная характеристика среды распространения (комплексная огибающая сигнала, отраженного от цели с единичной ФРП), задаваемая выражением [13].

$$\dot{g}(x, y) = G(x) \exp \left\{ -j \frac{4\pi}{\lambda} R(x) \right\} S(r - R(x)) \exp \left\{ \left( \phi j r - R(x) \right) \right\}, \quad (10.6)$$

где  $G(x)$  — ДН антенны по мощности;  $R(x)$  — закон изменения наклонной дальности;  $\lambda$  — длина волны;  $S(...)$  — закон амплитудной модуляции зондирующего сигнала;  $\phi(...)$  — закон фазовой внутриимпульсной модуляции.

Отраженный сигнал на входе системы обработки запишем в виде

$$\dot{S}(x, y) = \dot{\rho}(x, y) * \dot{g}(x, y) + \dot{n}(x, y), \quad (10.7)$$

где  $\dot{n}(...)$  — аддитивная помеха, учитывающая шумы приемника и другие искажения сигнала в апертуре РСА. Аддитивные шумы, как правило, относительно невелики (обычно менее  $-15$  дБ), поэтому вторым слагаемым в этом выражении можно пренебречь.

Далее сигнал подвергается свертке с импульсной характеристикой системы обработки сигнала в РСА (функция  $\dot{h}(...)$ )

$$\dot{U}(x, y) = \dot{S}(x, y) * \dot{h}(x, y), \quad (10.8)$$

и на выходе устройства обработки РЛИ определяется выражением

$$\dot{I}(x, y) = |\dot{U}(x, y)|^2. \quad (10.9)$$

Необходимо заметить, что для анализа влияния спекл-шума на РЛИ и методов его подавления данная модель отличается излишней детальностью, что приводит к неоправданной сложности. Поэтому введем ряд допущений, практически не влияющих на принципиальную сторону вопроса, но существенно упрощающих анализ:

- внутриимпульсная модуляция зондирующего сигнала отсутствует,
- диаграмма направленности антенны состоит только из одного лепестка и имеет постоянный коэффициент усиления в пределах этого лепестка,
- отсчеты РЛИ в азимутальном направлении следуют через расстояние, равное элементу разрешения.

При анализе сигнала в одном канале дальности и сделанных допущениях импульсная характеристика имеет вид:

$$\begin{aligned} g(x) &= \exp \left\{ -j \frac{4\pi}{\lambda} \sqrt{R_0^2 + (x - z)^2} \right\} \approx \\ &\approx \exp \left\{ -j \frac{2\pi}{\lambda R_0} (x - z)^2 \right\} \exp \left\{ -j \frac{4\pi R_0}{\lambda} \right\}, \end{aligned} \quad (10.10)$$

где  $z = Vt$  — координата носителя РЛС;  $V$  — скорость носителя. При этом сигнал, принимаемый в точке  $z$ , имеет вид:

$$S(z) = \int_{\Omega_x} \dot{\rho}(x) \exp \left\{ j \frac{4\pi}{\lambda R_0} \left( xz - \frac{z^2}{2} \right) \right\} dx, \quad (10.11)$$

где  $\Omega_x$  — протяженность наблюдаемого участка в одном канале дальности. В свою очередь, сигнал на выходе линейной части приемника может быть записан следующим образом:

$$\begin{aligned} \dot{U}(x) &= \int_{-\frac{L_c}{2}}^{\frac{L_c}{2}} \int_{\Omega_x} \dot{\rho}(x_0) \exp \left\{ j \frac{4\pi}{\lambda R} z(x - x_0) \right\} dx dz = \\ &= \int_{\Omega_x} \dot{\rho}(x_0) \frac{\sin \frac{2\pi L_c}{\lambda R_0} (x - x_0)}{\frac{2\pi}{\lambda R_0} (x - x_0)} dx \approx \\ &\approx \sum_k \dot{\rho}(k\Delta x_0) \int_{\Omega_x} \dot{\rho}(x_0) \frac{\sin \frac{2\pi L_c}{\lambda R_0} (x - k\Delta x_0)}{\frac{2\pi}{\lambda R_0} (x - k\Delta x_0)}, \end{aligned} \quad (10.12)$$

где  $\Delta x_0 = \frac{\lambda}{2L_c} R_0$  — интервал, равный длине элемента разрешения;  $L_c$  — длина синтезированной апертуры.

При выборе отсчетов выходного РЛИ также через интервал, равный элементу разрешения, для дискретного изображения получаем:

$$\dot{U}(n\Delta x_0) = \sum_k \dot{\rho}(k\Delta x_0) \frac{\sin \frac{2\pi L_c}{\lambda R_0} (x - k\Delta x_0)}{\frac{2\pi}{\lambda R_0} (x - k\Delta x_0)}. \quad (10.13)$$

Таким образом, выражение для РЛИ практически точно повторяет функцию радиолокационного рассеяния. Тем самым статистические характеристики РЛИ можно считать совпадающими с характеристиками ФРР (10.4):

$$U(x, y) = a'(x, y)(x, y), \quad (10.14)$$

где  $a'(x, y) = a_\Omega a(x, y)$ .

Если поверхность равномерно шероховатая ( $a(x, y) = \text{const}$ ), то в этом случае амплитуда отсчетов РЛИ распределена по релеевскому закону (рис. 10.3), а фаза — равномерна на интервале от  $-\pi$  до  $\pi$ .

На рис. 10.3 в качестве фрагмента шероховатой поверхности выбран участок морской поверхности (выделен на рисунке белым прямоугольником), полученный PCA *RadarSat* в детальном режиме съемки. Для этого участка построена гистограмма распределения яркости и рассчитаны среднее значение яркости, среднеквадратичное отклонение, коэффициент асимметрии и др. Вид кривой (гистограмма распределения яркости отсчетов выделенного фрагмента РЛИ) на графике и полученное значение коэффициента контраста подтверждают вывод о том, что яркость отсчетов радиолокационного изображения фрагмента шероховатой поверхности распределена по релеевскому закону.

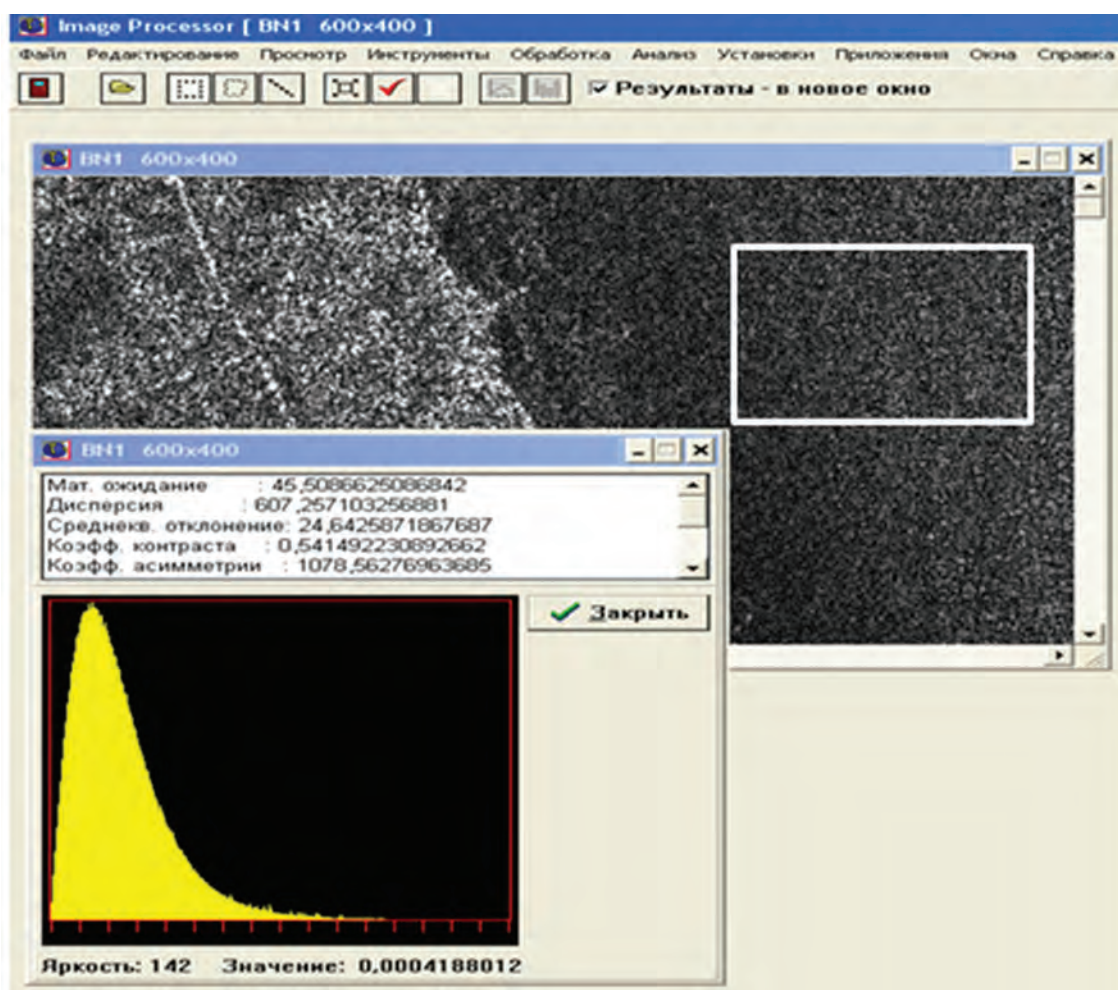


Рис. 10.3. Распределение яркости отсчетов РЛИ

Интенсивность отсчетов РЛИ при этом распределена по экспоненциальному закону:

$$p(I) = \frac{1}{2\sigma_0^2} \exp\left(-\frac{I}{2\sigma_0^2}\right) \quad (10.15)$$

со средним  $\bar{I} = 2\sigma_0$  и дисперсией  $\sigma_I^2 = 4\sigma_0^2$ . Отношение среднеквадратичного отклонения к среднему значению интенсивности будет при этом величиной постоянной и равной единице. А это, в свою очередь, означает, что изображение любой шероховатой поверхности, независимо от ее средней ЭПР, будет носить ярко выраженный пятнистый характер.

## 10.2. Характеристики реальных РЛИ протяженных целей

Важной характеристикой «изрезанности» РЛИ однородной поверхности является коэффициент контраста (отношение среднеквадратичного отклонения к среднему значению). Для экспоненциального распределения (10.15)

$$K_k = \frac{\sigma_I}{I} = 1. \quad (10.16)$$

Характеристики обратного рассеяния реальных протяженных объектов зависят от длины волны, влажности, угла наблюдения и т. п. [11, 13, 14]. Степень приближения в том или ином частотном диапазоне к идеальной шероховатой поверхности, лежащей в основе модели (10.14), зависит от наличия существенных неоднородностей. В этой связи распределение интенсивности реального РЛИ будет отличаться от (10.15).

В [8] показано, что распределения интенсивности РЛИ, полученные в экспериментах с различными РСА, от различных поверхностей и при различных условиях наблюдения, хорошо аппроксимируются гамма-распределением

$$p(I) = \frac{I^{c-1}}{b^c \Gamma(c)} \exp\left(-\frac{I}{b}\right), \quad (10.17)$$

где  $\Gamma(c)$  – гамма-функция;  $b = \hat{\sigma}^2 / \bar{I}$  и  $c = AN = \bar{I}^2 / \hat{\sigma}^2$  – параметры гамма распределения;  $N$  – число некогерентно суммируемых независимых изображений данного фрагмента.

Параметры гамма-распределения, полученные в результате эксперимента, приведены в табл. 10.1. Эти распределения могут быть использованы при моделировании отражений от поверхностей, указанных типов.

Таблица 10.1  
Параметры гамма-распределения

| Тип<br>РСА | №<br>п/п | Сюжет                                | С-параметр |            |            |
|------------|----------|--------------------------------------|------------|------------|------------|
|            |          |                                      | Х-диапазон | С-диапазон | Л-диапазон |
| USGS       | 1        | Травяное поле                        | 1,00       | 0,80       | 0,61       |
|            | 2        | 3-х летняя сосна                     | 0,97       | 0,83       | 0,51       |
|            | 3        | 30-ти летняя сосна                   | 0,70       | 0,77       | 0,76       |
|            | 4        | 50-ти летняя сосна                   | 0,79       | 0,72       | 0,79       |
|            | 5        | Смешанные дубы                       | 0,82       | 0,67       | 0,72       |
|            | 6        | Желтый тополь                        | 0,92       | 0,67       | 0,72       |
| SARSEX     | 7        | Поверхность моря<br>(ветер 5 узлов)  | 0,83       |            | 0,69       |
|            | 8        | Поверхность моря<br>(ветер 15 узлов) | 0,77       |            | 0,87       |
|            | 9        | Травяное поле                        | 0,83       |            | 0,61       |
|            | 10       | Картофельное поле                    | 0,89       |            | 0,62       |
|            | 11       | Поле с неубранным урожаем            | 0,59       |            | 0,47       |
|            | 12       | Поле с убраным урожаем               | 0,55       |            | 0,92       |
|            | 13       | Смешанный, сбросивший<br>листву лес  | 0,59       |            | 0,64       |
| MIZEX      | 14       | Однолетний лед                       | 0,70       |            | 0,86       |
|            | 15       | Двухгодичный лед                     | 0,84       |            | 0,73       |

### 10.3. Модель радиолокационного изображения точечной цели

На реальных РЛИ, кроме распределенных объектов, имеются и точечные цели. Последние являются идеализацией некоторых реальных целей, размеры которых существенно меньше элемента разрешения. Если флюктуациями фронта волны и эффективного центра отражения можно пренебречь, то сигнал от такой «блестящей точки» представляет собой квазидетерминированный процесс. Отклик РСА от «блестящей точки» в направлении движения носителя РСА (путевой дальности) можно описать следующим образом [15]:

$$S(n) = S_0 \frac{\sin \left[ \frac{\pi(n-n_0)N_c}{K_{\text{выб}}} \right]}{\frac{\pi(n-n_0)N_c}{K_{\text{выб}}}}, \quad (10.18)$$

где  $K_{\text{выб}}$  — коэффициент выборки, определяемый числом отсчетов РЛИ, приходящихся на элемент разрешения РСА;  $n_0$  — дискретная азимутальная координата «блестящей точки»;  $n$  — текущая дискретная азимутальная координата;  $N_c$  — число когерентно суммируемых отсчетов.

Отклик РСА на точечную цель в направлении наклонной дальности зависит от типа зондирующего сигнала и описывается его функцией неопределенности.

Модуль РЛИ элемента разрешения, содержащего точечную цель, наблюдаемую на фоне отражающей однородной поверхности, представляет собой случайную величину, распределенную по обобщенному релеевскому закону:

$$p(I) = \frac{1}{2\sigma_0^2} \exp\left(-\frac{I+S}{2\sigma_0^2}\right) I_0\left(\frac{\sqrt{IS}}{2\sigma_0^2}\right), \quad (10.19)$$

где  $I_0(\dots)$  — модифицированная функция Бесселя 1-го рода нулевого порядка.

Среднее значение для распределения равно  $\bar{y} = 2\sigma_0^2 + S$ , а дисперсия —  $\sigma_y^2 = 4\sigma_0^4 \left(1 + \frac{S}{\sigma_0^2}\right)$ . При этом аргумент отдельных элементов комплексного РЛИ  $\Psi_y$  имеет распределение [16]

$$p(\Psi) = \frac{1}{2\pi} \exp\left(-\frac{S}{2\sigma_0^2}\right) + \frac{\sqrt{S} \cos \Psi}{\sigma_0 \sqrt{2\pi}} \Phi\left(\frac{\sqrt{S}}{\sigma_0} \cos \Psi\right) \exp\left(-\frac{S}{2\sigma_0^2} \sin^2 \frac{\Psi}{2}\right), \quad (10.20)$$

где  $\Phi(\dots)$  — функция Лапласа.

### 10.4. Классификация алгоритмов фильтрации спекл-шума

Основной задачей на этапе восстановления (обработки) радиолокационных изображений является задача как можно более точного воспроизведения функции  $a(x, y)$  [23], характеризующей естественную отражающую способность поверхности. Для этой цели, как следует из выражения (10.14), необходимо, прежде всего, подавить мультипликативную шумовую составляющую или, иначе, спекл-шум.

Существующие в настоящее время методы сглаживания спекл-шума можно разделить на три группы (рис. 10.4): суммирование независимых РЛИ, глобальные и локальные процедуры фильтрации.





Рис. 10.4. Классификация алгоритмов фильтрации спекл-шума

В группу глобальных алгоритмов, предполагающих воздействие на все изображение или большую его часть, входят алгоритмы винеровской и калмановской фильтрации, процедуры с использованием гомоморфного преобразования поля РЛИ, а также геометрическая фильтрация. Теория и вопросы практической реализации этих методов подробно представлены в [23, 24, 25, 18].

Применение глобальных методов имеет целый ряд ограничений, которые обусловлены как существующей вычислительной трудоемкостью процедур фильтрации, так и спецификой методов.

Для калмановской (винеровской) фильтрации характерны [9]:

- необходимость априорной информации о статистических характеристиках неискаженного изображения и шума;
- сглаживание как спекл-шума, так и полезного сигнала, особенно в высокочастотной области спектра пространственных частот;
- сложность применения методов к пространственно неоднородным изображениям.

Гомоморфные преобразования ориентированы на чисто мультипликативную модель (10.14). Реальное же РЛИ представляет более сложную структуру, поэтому использование метода гомоморфной фильтрации часто не приводит к желаемому качеству сглаживания спекл-шума [17].

К недостаткам алгоритма геометрической фильтрации [18], наряду с его вычислительной сложностью, можно отнести зависимость количества итераций от величины средней ЭПР поверхности, что влечет за собой процедуру адаптации фильтра под обрабатываемую поверхность, а это, в свою очередь, ведет к еще большим вычислительным затратам.

В силу указанных особенностей рассмотренные глобальные методы не получили широкого распространения. Наиболее часто на практике используются первая и последняя группы алгоритмов, поэтому ниже остановимся на них подробнее.

#### 10.4.1. Суммирование независимых РЛИ

Как отмечалось выше, один из эффективных способов снижения спекл-шума — суммирование нескольких независимых РЛИ одного и того же участка поверхности. Получить такие изображения можно, несколько раз пролетая над одной и той же территорией, что далеко не всегда возможно по тактическим и техническим соображениям [2, 21]. Другой метод заключается в создании изображений с использованием разных поляризаций излучаемого и принимаемого сигналов, что, однако, не позволяет в большинстве случаев получить достаточного количества независимых РЛИ одного участка поверхности [5, 27]. Поэтому предпочтение на практике отдается многолучевой обработке — методу, при котором некоррелированные изображения получаются из сигналов с неперекрывающимися спектрами. Получить такие изображения можно, например, разбив ДН реальной антенны в азимутальной плоскости  $\theta_\Sigma$  на несколько частей  $\theta_i$ , как это показано на рис. 10.5.

Остановимся подробнее на этом методе.

При суммировании  $N$  независимых РЛИ с экспоненциальной функцией распределения интенсивности (10.15), получаем изображение, интенсивность которого распределена по закону:

$$p(I) = \frac{1}{\left(\frac{\sigma}{N}\right)(N-1)!} \left(\frac{I}{\frac{\sigma}{N}}\right)^{N-1} \exp\left(-\frac{I}{\frac{\sigma}{N}}\right). \quad (10.21)$$




Рис. 10.5. Боковой обзор с использованием многолучевой ДН антенны по азимуту

Отношение среднеквадратичного отклонения к среднему значению для такого распределения равно  $1/\sqrt{N}$ . Таким образом, при усреднении  $N$  независимых РЛИ пятнистость результирующего изображения уменьшается в  $\sqrt{N}$  раз.

На рис. 10.6 представлено изображение, полученное суммированием четырех независимых снимков одной и той же сцены. Снимки получены за счет разбиения диаграммы направленности реальной антенны на четыре части. Разбиение проводилось на этапе синтезирования апертуры в цифровой форме. Из сопоставления данного рисунка с рис. 10.3 видно, что суммирование независимых отсчетов приводит к нормализации гистограммы распределения яркости отсчетов изображения для шероховатой поверхности. А изменение значения коэффициента контраста подтверждает, что отношение сигнал/шум при суммировании  $N$  отсчетов увеличивается в  $\sqrt{N}$  раз.

Однако данный прием обработки обладает существенным недостатком – пропорционально количеству суммируемых изображений ухудшается разрешающая способность РСА при неизменных параметрах зондирующего сигнала.

Чтобы понять природу этого явления, запишем выражение для разрешения по дальности  $\delta r$  и азимуту  $\delta x$ . Как известно, они определяются шириной полосы сигнала  $\Delta f_c$  и шириной доплеровского спектра  $\Delta f_d$  соответственно

$$\begin{aligned}\delta r &= \frac{C}{\Delta f_c}; \\ \delta x &= \frac{V}{\Delta f_d}.\end{aligned}\tag{10.22}$$

Здесь  $C$  – скорость распространения электромагнитной волны в вакууме;  $V$  – скорость носителя РСА.

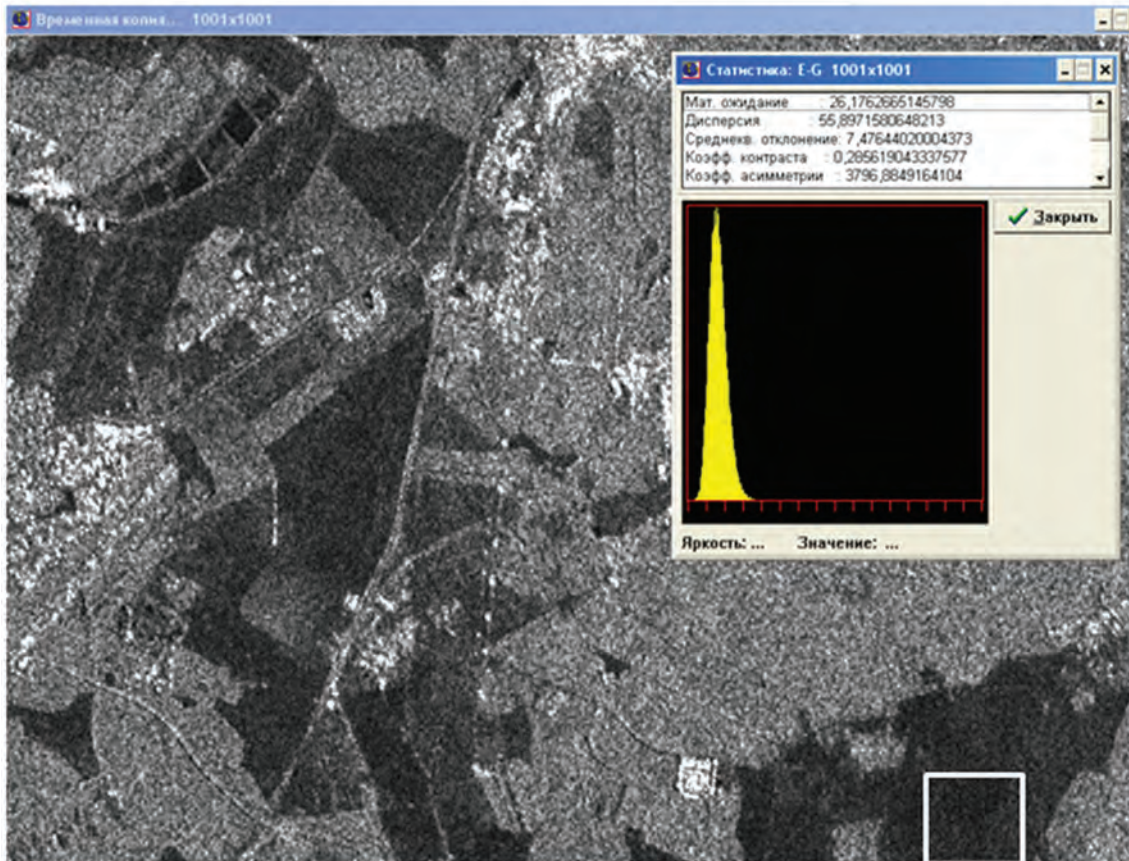


Рис. 10.6. Распределение яркости отсчетов РЛИ при многолучевой обработке

Разделив спектры на  $N_r$  и  $N_x$  частей соответственно, можно получить

$$N = N_r N_x \quad (10.23)$$

некоррелированных изображений. При этом разрешение по дальности и азимуту соответственно ухудшится до

$$\begin{aligned} \delta R &= \frac{N_r C}{\Delta f_c}; \\ \delta X &= \frac{N_x V}{\Delta f_d}. \end{aligned} \quad (10.24)$$

Таким образом, многолучевая обработка позволяет снизить уровень спекл-шума, но при этом пропорционально ухудшается пространственное разрешение РЛИ. В связи с этим в большинстве случаев приходится принимать компромиссное решение.

Другим недостатком данного метода является дискретный характер изменения разрешения (невозможность плавного его изменения), а соответственно, и уровня спекл-шума. Устранить данный недостаток можно за счет использования частичного перекрытия подапертур (доплеровских спектров) [26]. Здесь и далее будем рассматривать многолучевую обработку с лучами ДН синтезированной антенны, разнесенными только в азимутальном направлении.



На рис. 10.7 (кривая 1) показана зависимость уровня спекл-шума (нормированное значение коэффициента контраста) от величины перекрытия подапертур для случая четырехобзорной обработки.

$$\beta = \frac{L_x - L_c / N_x}{L_x}, \quad (10.25)$$

где  $L_c$  и  $L_x$  — длина синтезированной апертуры и длина подпертуры соответственно.




Рис. 10.7. Зависимость уровня спекл-шума от величины перекрытия подапертур для случая четырехобзорной обработки

Проиллюстрируем преимущества данного способа обработки на следующем примере. PCA ERS-1 при длине антенны 10 м имеет потенциальное разрешение по азимуту 5 м [27]. Необходимо получить РЛИ с разрешающей способностью не хуже 18 м и наименьшей пятнистостью.

Обычная трехобзорная обработка удовлетворяет требованию по разрешению и дает снижение спекла примерно в 1,7 раза (до 0,59). В то же время четырехобзорная обработка с коэффициентом перекрытия подапертур  $\beta = 0,133$  обеспечивает разрешающую способность РЛИ 18 м, а уровень спекла при этом составляет 0,57, что говорит в пользу второго способа обработки.

Дальнейшего уменьшения пятнистости РЛИ без ухудшения пространственного разрешения можно добиться за счет неравномерности наложения близлежащих подапертур. Оптимальные величины наложения  $\beta_i$  в зависимости от среднего их перекрытия  $\beta_{\text{ср}}$  для случая четырехобзорной обработки приведены в табл. 10.2, а график зависимости пятнистости от  $\beta_{\text{ср}}$  — на рис. 10.7 (кривая 2).

Другой способ, также позволяющий несколько снизить спекл-шум, — это суммирование обзоров со своими весовыми коэффициентами. Данный вывод вытекает из утверждения, что наименее коррелированным подапертурам, которыми, несомненно, являются крайние, следует придавать большие веса. Оптимальные весовые коэффициенты  $\alpha_i$  при тех же условиях, что и в предыдущем эксперименте, приведены в табл. 10.3, а соответствующий график на рис. 10.7 (кривая 3).



Таблица 10.2

Оптимальные значения  $\beta_i$  при четырехобзорной обработке

| $\beta_{cp}$ | $\beta_1$ | $\beta_2$ | $\beta_3$ |
|--------------|-----------|-----------|-----------|
| 0,00         | 0,00      | 0,00      | 0,00      |
| 0,10         | 0,00      | 0,30      | 0,00      |
| 0,20         | 0,00      | 0,60      | 0,00      |
| 0,30         | 0,00      | 0,90      | 0,00      |
| 0,40         | 0,10      | 1,00      | 0,10      |
| 0,50         | 0,25      | 1,00      | 0,25      |
| 0,60         | 0,41      | 0,98      | 0,41      |
| 0,70         | 0,56      | 0,98      | 0,56      |
| 0,80         | 0,71      | 0,98      | 0,71      |
| 0,90         | 0,85      | 1,00      | 0,85      |
| 1,00         | 1,00      | 1,00      | 1,00      |

Использование оптимальных весовых коэффициентов и интервалов перекрытия подапертур при азимутальном сжатии сигнала, как показал эксперимент, увеличивает радиолокационное разрешение, вычисляемое по формуле

$$\gamma = 10 \lg(1 + \sigma / \bar{I}), \quad (10.26)$$

соответственно на 0,125 и 0,33 дБ для случая четырех подапертур.

Таблица 10.3

Оптимальные коэффициенты  $\alpha_i$

| $\alpha_{cp}$ | $\alpha_1$ | $\alpha_2$ | $\alpha_3$ | $\alpha_4$ |
|---------------|------------|------------|------------|------------|
| 0,00          | 1,22       | 0,78       | 0,78       | 1,22       |
| 0,10          | 1,25       | 0,75       | 0,75       | 1,25       |
| 0,20          | 1,28       | 0,72       | 0,72       | 1,28       |
| 0,30          | 1,32       | 0,68       | 0,68       | 1,32       |
| 0,40          | 1,37       | 0,63       | 0,63       | 1,37       |
| 0,50          | 1,42       | 0,58       | 0,58       | 1,42       |
| 0,60          | 1,62       | 0,38       | 0,38       | 1,62       |
| 0,70          | 1,93       | 0,07       | 0,07       | 1,93       |
| 0,80          | 1,92       | 0,08       | 0,08       | 1,92       |
| 0,90          | 1,93       | 0,07       | 0,07       | 1,93       |
| 1,00          | 2,00       | 0,00       | 0,00       | 2,00       |

Таким образом, многолучевая обработка позволяет снизить уровень спекла пропорционально корню квадратному из количества используемых лучей. Но при этом соответственно ухудшается пространственное разрешение РЛИ. Несколько уменьшить данное противоречие позволяет использование частичного перекрытия лучей и дополнительная весовая обработка.

Одним из основных преимуществ алгоритма усреднения является то, что уровень спекл-шума регулируется на этапе формирования РЛИ, а не после того, как оно уже получено, что сокращает вычислительные затраты на этапе дешифрирования РЛИ.

#### 10.4.2. Локальные алгоритмы обработки РЛИ

Отличительной особенностью этой группы алгоритмов обработки РЛИ является тот факт, что непосредственная обработка ведется в «скользящем окне», которое перемещается по изображению. Поскольку размеры этого «окна» невелики (обычно не более  $11 \times 11$  отсчетов) по сравнению со всем изображением, то быстродействие алгоритмов значительно выше, чем у глобальных [10]. Данную группу образуют следующие алгоритмы:

- усреднение в скользящем окне. Выражение для значения яркости в точке изображения с координатами  $(i, j)$ , полученное в результате фильтрации имеет вид

$$\hat{a}_{ij} = \sum_{k=i-m_1}^{i+m_1} \sum_{l=j-m_2}^{j+m_2} I_{kl}, \quad (10.27)$$

где  $I_{kl}$  — значение яркости в точке «окна» с координатами  $(k, l)$  на входе фильтра;  $m_1$  и  $m_2$  — размеры окна обработки по горизонтали и вертикали соответственно;

- медианная фильтрация

$$\hat{a}_{ij} = \text{med}_{k=i \pm m_1, l=j \pm m_2} (I_{kl}); \quad (10.28)$$

- подгруппа адаптивных алгоритмов, а также различные их модификации.

Адаптивные алгоритмы, несколько проигрывая первым двум в быстродействии, обладают неоспоримым преимуществом перед ними. Они точнее отслеживают все изменения функции  $a(x, y)$ . Это связано с тем, что параметры алгоритмов меняются в зависимости от статистических характеристик фрагмента РЛИ, ограниченного текущим положением «окна» обработки. При этом допускается, что статистика данного блока представляет собой статистику выборки элемента изображения в центре этого блока. Для точной оценки истинного значения этого элемента необходимо, чтобы размер блока был достаточно большим. Однако неоднородность поверхности и дополнительные вычислительные затраты существенно ограничивают размер окна обработки, что, в свою очередь, приводит к ошибке в оценке параметров алгоритма фильтрации, а следовательно, к потере четкости на изображении, ограничивая тем самым возможности данной группы алгоритмов. Тем не менее, это направление сглаживания спекл-шума считается сегодня наиболее перспективным. Его образуют следующие алгоритмы (см. рис. 10.4): фильтрация методом Ли, сигма-фильтрация, локальная адаптивная фильтрация, фильтрация Фроста и их возможные модификации.

Ниже остановимся подробнее на описании этих алгоритмов.

#### Фильтрация методом локальных статистик (метод Ли)

Метод был впервые предложен в [7]. В основе метода лежит мультипликативная модель спекл-шума, согласно которой каждый элемент РЛИ  $I_{ij}$  представляется как произведение сигнала  $a_{ij}$  и шума  $v_{ij}$ . Причем шум имеет среднее значение  $\bar{v} = 1$  и дисперсию  $\sigma_v^2$ . Кроме того, сигнал и шум считаются независимыми.

При разложении  $I$  в ряд Тейлора и учете только членов первого порядка получаем

$$I = \bar{v}a + \bar{a}(v - 1). \quad (10.29)$$

Минимизация среднего квадрата ошибки подавления спекл-шума приводит к следующему выражению для оценки  $\hat{a}$ :

$$\hat{a} = \bar{I} + \frac{\bar{v}^2 \sigma_a^2}{\bar{I}^2 \sigma_v^2 + \bar{v}^2 \sigma_a^2} (I - \bar{I}), \quad (10.30)$$

где  $\sigma_a^2$  — дисперсия неискаженного шумами изображения в «окне» обработки, оценка которого формируется в соответствии с равенством

$$\sigma_a^2 = \frac{\bar{v}^2 \sigma_I^2 - \bar{I}^2 \sigma_v^2}{\bar{v}^2}, \quad (10.31)$$

$\bar{I}$  — среднее значение яркости РЛИ в «окне» обработки;  $\sigma_I^2$  — дисперсия яркости в окне обработки. Среднее значение мультипликативного шума  $\bar{v}$  равно 1, а дисперсию спекл-шума необходимо определять по фрагменту изображения однородного участка поверхности в соответствии с выражением

$$\sigma_v^2 = \frac{\sigma_I^2}{\bar{I}^2}, \quad (10.32)$$

либо рассчитывать с учетом всех параметров РЛС.

При неправильном определении параметра  $\sigma_v$  ухудшаются адаптивные свойства фильтра. Если увеличивать значение, то процедура фильтрации постепенно приближается к обычному усреднению в «скользящем» окне, при уменьшении  $\sigma_v$  снижаются фильтрующие свойства процедуры обработки.

Как уже отмечалось выше, фильтр Ли обладает адаптивными свойствами к характеру наблюдаемой сцены. Так, например, в «плоском» районе, где  $\sigma_a^2 \approx 0$ , значение  $\hat{a}$  будет рассчитываться как среднее в окне обработки. В районе же с высокой контрастностью ( $\sigma_a^2$  велика по сравнению с  $\bar{a}^2 \sigma_v^2$ ) оценка  $\hat{a}$  примерно равна самому этому значению.

### Локальная адаптивная фильтрация

В основе алгоритма [28] лежит также мультипликативная модель спекл-шума, однако она преобразована к следующему виду:

$$I = a + (v - 1)a = a + N. \quad (10.33)$$

Среднее значение аддитивного шума в данном выражении равняется нулю.

Его дисперсию можно получить как

$$\sigma_N^2 = \sigma_a^2 + \bar{a}^2. \quad (10.34)$$

Как и ожидалось, статистика шума зависит от сигнала.

Оценка  $\hat{a}$  для данной модели равна

$$\hat{a} = \bar{a} + \frac{\sigma_a^2}{\bar{a}^2 + 2\sigma_a^2} (I - \bar{I}). \quad (10.35)$$

Очевидно, что фильтр стремится уравнивать области с малой изрезанностью, сохраняя при этом границы (области с большим значением  $\sigma_a^2$ ).

Находя  $\sigma_a^2$  получаем

$$\sigma_a^2 = \frac{\sigma_I^2 - \bar{I}^2}{2}. \quad (10.36)$$

Подставив (10.36) в (10.35), рассчитываем окончательное выражение, описывающее локальный адаптивный фильтр:

$$\hat{a} = \bar{I} + 0,5 \left( 1 - \frac{\bar{I}^2}{\sigma_I^2} \right) (I - \bar{I}). \quad (10.37)$$

Следует рассмотреть особые случаи, когда алгоритм не работает. Оба таких случая имеют место при условии, когда статистические характеристики текущего фрагмента РЛИ не удовлетворяют модели сигнала:

- отношение  $\frac{\bar{I}^2}{\sigma_I^2}$  больше 1 (низкий уровень спекл-шума). В данном случае, согласно выражению (10.36), оценка дисперсии сигнала принимает отрицательное значение;
- отраженный сигнал состоит из сильной когерентной составляющей и слабой диффузионной (на изображении одна или несколько ярких «блестящих точек»). Для таких участков отношение  $\frac{\bar{I}^2}{\sigma_I^2} > 4$ , и авторы [28] рекомендуют в данном случае коэффициент усиления фильтра принимать равным 1.

### Сигма-фильтрация

Статистика сигма-фильтра опирается на свойство дисперсии нормальнораспределенной случайной величины, вероятность попадания которой в интервал  $\pm 2\sigma$  где  $\sigma$  – дисперсия, составляет 0,9. Оценка  $\hat{a}_{ij}$  в соответствии с данным методом определяется как

$$\hat{a} = \sum_{k=i-m_1}^{j+m_1} \sum_{l=j-m_2}^{j+m_2} \delta_{kl} I_{kl} / \sum_{k=i-m_1}^{j+m_1} \sum_{l=j-m_2}^{j+m_2} \delta_{kl}, \quad (10.38)$$

где 
$$\delta_{kl} = \begin{cases} 1, & \text{если } (1 - K_v \sigma_v) I_{ij} \leq I_{kl} \leq (1 + K_v \sigma_v) I_{ij}, \\ 0, & \text{в остальных случаях} \end{cases} \quad (10.39)$$

а  $K_v$  – коэффициент, определяющий адаптивные свойства фильтра.

Авторами [29] рекомендуется принимать значение  $K_v$  равным 2. Увеличение  $K_v$  способствует лучшему сглаживанию шумов, однако, не следует забывать, что при этом сильнее «размывается» изображение. Уменьшение  $K_v$  приводит к обратному эффекту, т.е. ухудшается фильтрация шума, но при этом лучше прописываются мелкие детали на изображении.

К недостаткам данного фильтра следует отнести невозможность априорно оценить поведение ошибки подавления спекл-шума.

Несомненным достоинством фильтра является его простота, а, следовательно, вычислительная эффективность и наличие адаптивных свойств.

Возможно несколько «проходов» фильтра по РЛИ, причем его параметры при этом могут быть различны [10].

### Фильтрация Фроста

В основу алгоритма автор, чьим именем назван фильтр, положил модель спекл-шума (10.14) [30].

Минимизируя средний квадрат ошибки

$$\varepsilon^2 = E \left\{ (a(t) - h(t) * I(t))^2 \right\},$$

$$\varepsilon^2 = E\{(a(t) - h(t)*I(t))^2\}, \quad (10.40)$$

где  $*$  — обозначение свертки;  $h(t)$  — импульсная характеристика фильтра, сглаживающего спекл-шум, получаем выражение для частотной характеристики фильтра Фроста в следующем виде:

$$M(f) = \frac{\bar{v}S_a(f)H(f) - \bar{v}a^2\delta(f)}{(S_a(f)*S_v(f))|H(f)|^2 - (\bar{v}a)^2\delta(f)}. \quad (10.41)$$

Здесь  $S_a(f)$  — спектральная плотность мощности  $a(t)$ ;  $S_v(f)$  — спектральная плотность мощности  $v(t)$ ;

$$H(f) = \int_{-\infty}^{\infty} h(t)\exp(j2\pi ft)dt. \quad (10.42)$$

Допуская, что

$$H(f) = \text{rect}_B(f), \quad (10.43)$$

где  $B$  — ширина полосы пропускания, а сигнал и шум имеют следующие ковариационные функции:

$$\begin{aligned} R_v(\tau) &= \sigma_v^2\delta(\tau) + \bar{v}^2; \\ R_a(\tau) &= \sigma_a^2\exp(-\alpha|\tau|) + \bar{a}^2, \end{aligned} \quad (10.44)$$

получаем выражение для импульсной характеристики фильтра в следующем виде:

$$h(t) = \frac{2\bar{v}\gamma}{2\bar{v}\sigma_a^2 + \sigma_v^2(a^2 + \sigma_a)^2} \exp(-\gamma|t|), \quad (10.45)$$

$$\gamma = \sqrt{\frac{2\alpha(\bar{v}/\sigma_v)^2}{1 + (\bar{a}/\sigma_a)^2}} + \alpha. \quad (10.46)$$

Теоретически фильтр работоспособен только для «однородных районов». Однако, если параметр адаптируется относительно условий сцены, то фильтр почти не деградирует и на границе областей с различной ЭПР. Действительно, чем больше  $\sigma_a$  (изрезанность поверхности), тем больше  $\gamma$  и тем короче импульсная характеристика фильтра обработки, а, следовательно, тем меньше будет усредняться сигнал.

Можно показать, что

$$\gamma = K_2(\sigma_l/\bar{I})^2, \quad (10.47)$$

где  $K_2$  — коэффициент пропорциональности [30].

Таким образом, выражение для оценки  $\hat{a}_{ij}$ , характеризующей местную отражающую способность, при фильтрации методом Фроста имеет вид

$$\hat{a}_{ij} = \sum_{k=-m_1}^{i+m_1} \sum_{l=-m_2}^{j+m_2} I_{kl} K_1 \exp\left(-K_2 \frac{\sigma_l^2}{\bar{I}^2} \sqrt{k^2 + l^2}\right), \quad (10.48)$$

где  $K_1$  — коэффициент для нормировки.



## 10.5. Моделирование работы алгоритмов фильтрации спекл-шума

Отсутствие всеобъемлющих объективных критериев для оценки сглаживания спекл-шума в течение длительного времени не позволяло однозначно выделять среди множества различных процедур такие, которые в наилучшей степени удовлетворяли бы запросам потребителя. Оценка производилась, как правило, на экспертном уровне. А поскольку при обработке РЛИ решались (и решаются) различные прикладные задачи, то и выводы о преимуществе того или иного алгоритма не всегда совпадали.

В данной главе представлены результаты исследования фильтрующих свойств локальных алгоритмов с использованием следующих критериев [21, 85]:

- для оценки уровня шума (спекл-шума) производился расчет коэффициента контраста для участка шероховатой поверхности,
- для оценки пространственного разрешения вычисляется ширина отклика от яркой точечной цели («блестящей точки»), расположенной на слабоотражающем фоне.

### 10.5.1. Снижение уровня спекл-шума

Одним из показателей качества сглаживания спекл-шума предложено считать отношение среднеквадратичного отклонения амплитуды отсчетов сигнала к его среднему значению [10]. Это отношение вычисляется для однородной области изображения:

$$K_k = \frac{\sigma_I}{I}. \quad (10.49)$$

Отношение (10.49) позволяет качественно оценить степень уменьшения дисперсии флуктуаций шума вследствие применения выбранной процедуры сглаживания.

Оценка фильтрующих свойств процедур, описанных выше, проводилась с использованием модели изображения идеально шероховатой поверхности (выражения (10.14)–(10.15)). При этом для формирования модели действительного РЛИ протяженной однородной поверхности имитировалось комплексное гауссовское случайное поле, имеющее нулевое среднее, а затем вычислялся квадрат модуля.

Среднее значение амплитуды отсчетов и среднеквадратичное отклонение вычислялись до и после обработки этого изображения тем или иным фильтром, после чего проводился расчет коэффициента контраста («пятнистости» изображения).

Нормированное значение оценки  $K_k$  для большинства описанных в предыдущем параграфе локальных алгоритмов сглаживания спекл-шума для различных размеров скользящего окна обработки приведены в табл. 10.4 и на графике рис. 10.8.

Таблица 10.4  
Нормированное значение  $K_k$

| №<br>п/п                   | Тип фильтра                 | Размер окна обработки |               |               |      |      |
|----------------------------|-----------------------------|-----------------------|---------------|---------------|------|------|
|                            |                             | 1×1                   | 3×3           | 5×5           | 7×7  | 9×9  |
| 1                          | Усредняющий                 | 1,00                  | 0,33          | 0,15          | 0,12 | 0,10 |
| 2                          | Медианный                   | 1,00                  | 0,43          | 0,26          | 0,18 | 0,14 |
| 3                          | Сигма-фильтр                | 1,00                  | 0,62          | 0,54          | 0,51 | 0,51 |
| 4                          | Фильтр Ли                   | 1,00                  | 0,38          | 0,23          | 0,16 | 0,13 |
| 5                          | Локальный адаптивный фильтр | 1,00                  | 0,47          | 0,27          | 0,18 | 0,14 |
| Некогерентное суммирование |                             | 2 изображения         | 4 изображения | 8 изображений |      |      |
|                            |                             | 0,71                  | 0,50          | 0,35          |      |      |




Рис. 10.8. Зависимость уровня спекл-шума от размера окна обработки фильтра

Для сравнения эффективности локальных процедур фильтрации РЛИ с алгоритмом подавления спекл-шума посредством суммирования нескольких независимых изображений одного и того же участка поверхности (10.21) в нижней части

Из полученных результатов следует, что лучше всего шум может быть подавлен на однородных областях изображения путем усреднения отсчетов в окне обработки и менее эффективен здесь сигма-фильтр (коэффициент  $K_v$  при  $\sigma_v$  равен 2). Остальные алгоритмы примерно равны по своим качественным показателям, и уже при размере окна обработки  $5 \times 5$  отсчетов значительно лучше сглаживают спекл-шум, чем классическое суммирование независимых РЛИ.

### 10.5.2. Ухудшение пространственного разрешения

Однако следует отметить, что все алгоритмы подавления спекла обладают и рядом недостатков. К ним относятся: ухудшение пространственного разрешения РЛИ, размытие границ областей изображения с различной ЭПР и т. д.

Для примера в табл. 10.5 и на рис. 10.9 приведены данные, характеризующие ухудшение пространственного разрешения после использования той или иной фильтрующей процедуры. Они также являются нормированными и получены путем моделирования. Для тестирования алгоритмов в данном случае использовалась модель изображения «блестящей точки» (10.18) на слабо отражающем фоне. Пространственное разрешение оценивалось по уровню половинной мощности.

Таблица 10.5

Нормированное значение пространственного разрешения

| № п/п                      | Тип фильтра                 | Размер окна обработки |      |               |      |               |
|----------------------------|-----------------------------|-----------------------|------|---------------|------|---------------|
|                            |                             | 1×1                   | 3×3  | 5×5           | 7×7  | 9×9           |
| 1                          | Усредняющий                 | 1,00                  | 2,07 | 3,08          | 4,53 | 5,79          |
| 2                          | Медианный                   | 1,00                  | 1,67 | 2,33          | 3,11 | 3,57          |
| 3                          | Сигма-фильтр                | 1,00                  | 1,16 | 1,31          | 1,34 | 1,54          |
| 4                          | Фильтр Ли                   | 1,00                  | 1,82 | 2,58          | 3,00 | 3,32          |
| 5                          | Локальный адаптивный фильтр | 1,00                  | 1,72 | 2,53          | 3,36 | 3,91          |
| Некогерентное суммирование |                             | 2 изображения         |      | 4 изображения |      | 8 изображений |
|                            |                             | 2,00                  |      | 4,00          |      | 8,00          |

Из сопоставления полученных результатов (табл. 10.4 и 10.5) можно сделать вывод, что чем лучше при фильтрации сглаживается спекл-шум, тем хуже становится его пространственное разрешение (сильнее размываются на РЛИ границы областей с различной ЭПР).

### 10.5.3. Моделирование работы фильтра Фроста

Оценка эффективности работы фильтра Фроста проводилась с использованием тех же тестовых снимков и тех же критериев, что и остальных процедур фильтрации. На рис. 10.10 (кривая 1) показан график зависимости нормированного значения коэффициента контраста, который характеризует уровень спекл-шума на РЛИ, от  $K_2$  (10.47), на рис. 10.11 (кривая 1) – нормированного значения пространственного разрешения обработанного изображения от  $K_2$ .




Рис. 10.9. Зависимость пространственного разрешения РЛИ от размеров окна обработки фильтра

Из графиков видно, при больших значениях  $K_2$  ( $K_2 > 4,5$ ) разрешение практически не отличается от исходного, а коэффициент контраста близок к единице. Это объясняется тем, что импульсная характеристика фильтра очень «короткая» (при неограниченном увеличении  $K_2$  она стремится к  $\delta$ -функции) и шум практически не сглаживается.

При малых значениях  $K_2$  ( $K_2 < 1$ ) наблюдается обратный эффект – происходит простое усреднение отсчётов в окне обработки без учёта особенностей изображения (при  $K_2$  равно 0 имеем простое усреднение в «скользящем» окне). При этом подавление шума максимально, но пространственное разрешение снимка наихудшее.

Наиболее оптимальными можно считать значения  $K_2$  в интервале 0,5–2,5. При этих значениях сглаживание спекл-шума близко к максимальному, а пространственное разрешение ухудшается незначительно.

Несколько превосходя другие фильтры по своим качественным показателям [32] фильтр Фроста уступает им в быстродействии, так как его вычислительный алгоритм содержит достаточно много операций умножения.

Другим существенным недостатком можно считать неопределенный размер окна обработки фильтра Фроста. В общем случае размер окна обработки бесконечен, т.е. ограничен только размерами самого изображения, однако при значении  $K_2$  близком

к оптимальному, веса отсчетов, удаленных от центрального, ничтожно малы и практически без потери качества можно ограничиться размером «скользящего» окна обработки размером  $11 \times 11$  отсчетов. Такое ограничение позволяет ускорить обработку.



Рис. 10.10. Зависимость уровня спекл-шума от величины  $K_2$




Рис. 10.11. Зависимость пространственного разрешения от величины  $K_2$

Дальнейшего увеличения вычислительной эффективности можно добиться путем аппроксимации экспоненциальных импульсных характеристик прямоугольными (рис. 10.12). При этом обработка изображения сводится к обычному усреднению в «скользящем окне», размеры которого зависят от  $K_2 (\sigma_i^2 / \bar{I}^2)$  (ширины импульсной характеристики фильтра) и могут принимать значения  $11 \times 11, 9 \times 9, \dots, 1 \times 1$ .

При малом значении  $\sigma_i^2 / \bar{I}^2$  размер окна обработки максимален и спекл-шум сглаживается наилучшим образом. Если же радиолокационный рельеф резко неоднороден ( $\sigma_i^2 / \bar{I}^2$  достаточно велико), то размер окна обработки, а, следовательно, сглаживающие свойства фильтра минимальны. Однако при этом лучше отслеживаются все неоднородности наблюдаемой поверхности.

Новая структура фильтра позволяет полностью исключить операции умножения из процесса вычислений и существенно сократить количество операций сложения.

Изменяя уровень  $Y$  можно влиять на быстродействие фильтров, увеличивая или уменьшая ширину их импульсных характеристик, однако при этом будут меняться и качественные характеристики обработанных снимков.





Рис. 10.12. Аппроксимация импульсных характеристик фильтра Фроста

Характеристики модифицированного фильтра Фроста приведены на рис. 10.13 и 10.14. Из графиков видно, внесенные изменения в структуру существенно сократили диапазон возможных значений  $K_2$  (кривые идут круче), то есть адаптивные возможности фильтра ограничились. Кроме того, модифицированная процедура фильтрации несколько уступает базовой и по интегральному качественному критерию (снижение уровня шума на ухудшение разрешения), приближаясь по этому показателю к другим адаптивным фильтрам [32].


 Рис. 10.13. Зависимость пространственного разрешения от величины  $K_2$  для обычного и модифицированного фильтра Фроста






Рис. 10.14. Зависимость коэффициента контраста от величины  $K_2$  для обычного и модифицированного фильтра Фроста

Приведенные результаты позволяют сделать вывод, что существенно сократить вычислительные затраты при фильтрации радиолокационных данных методом Фроста можно путем аппроксимации реальной импульсной характеристики фильтра прямоугольной. Однако при этом несколько ухудшаются качественные показатели обработанного изображения. То есть, при выборе фильтрующей процедуры и ее параметров необходимо принимать компромиссное решение, исходя из требований качества и скорости обработки.

## 10.6. Результаты обработки реальных РЛИ

В данном разделе представлены результаты обработки реальных радиолокационных изображений космического аппарата *RadarSAT*.

Для сравнения фильтрующих свойств алгоритмов фильтрации оценка коэффициента контраста проводилась по фрагменту, содержащему однородную поверхность — море. Результаты представлены в табл. 10.6 и на графике (рис. 10.15).

Таблица 10.6.  
Фильтрация спекл-шума на реальных изображениях

| №<br>п/п | Тип Фильтра                 | Значение $K_K$        |      |      |      |      |
|----------|-----------------------------|-----------------------|------|------|------|------|
|          |                             | Размер окна обработки |      |      |      |      |
|          |                             | 1×1                   | 3×3  | 5×5  | 7×7  | 9×9  |
| 1        | Усредняющий                 | 0,54                  | 0,18 | 0,08 | 0,06 | 0,05 |
| 2        | Медианный                   | 0,54                  | 0,24 | 0,14 | 0,10 | 0,08 |
| 3        | Сигма-фильтр                | 0,54                  | 0,33 | 0,29 | 0,28 | 0,27 |
| 4        | Фильтр Ли                   | 0,54                  | 0,25 | 0,17 | 0,13 | 0,09 |
| 5        | Локальный адаптивный фильтр | 0,54                  | 0,25 | 0,20 | 0,16 | 0,13 |

Несколько завышенное значение коэффициента контраста (уровень спекл-шума) для исходного изображения по сравнению с теоретическим можно объяснить естественной изменчивостью отражающих свойств поверхности (например, волнением моря).

Результаты, аналогичные приведенным в табл. 10.6, получены и в других экспериментах (для других поверхностей).




Рис. 10.15. Сравнение результатов обработки реальных РЛИ и изображений, полученных путем моделирования

На рис. 10.15 показано, как соотносятся результаты, полученные при обработке реального снимка и модели РЛИ усредняющим и фильтром Ли соответственно.

Оценить степень размытия границ областей с различной ЭПР и ухудшение разрешения снимка по реальным данным количественно достаточно сложно из-за отсутствия достоверной информации о характере сюжета.

Однако эффект ухудшения пространственного разрешения снимка и связанное с этим размытие границ областей, отличающихся ЭПР, при фильтрации спекл-шума хорошо виден при визуализации снимка (рис. 10.16).

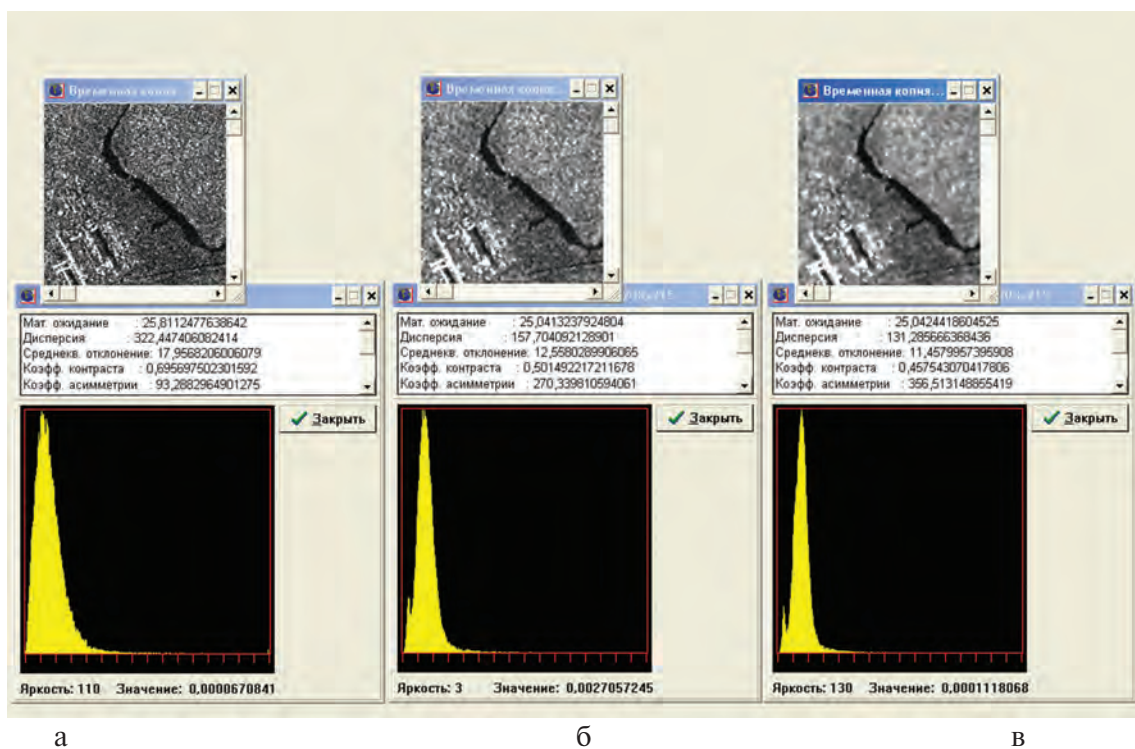


Рис. 10.16. РЛИ и его характеристики:

а — исходный снимок; б — снимок после обработки сигма-фильтром с размером окна 3\*3;  
в — снимок после обработки сигма-фильтром с размером окна 5\*5

На рис. 10.16, а приведен фрагмент исходного изображения. Завышенное значение коэффициента контраста (по сравнению с теоретическим) объясняется тем, что расчет контраста проводился по всему снимку, а поверхность на снимке достаточно неоднородна.

Визуально исходное изображение воспринимается предпочтительнее, чем обработанные снимки (рис. 10.16, б и 10.16, в). Это объясняется психофизическими свойствами зрения человека [23]. Человеческий глаз выполняет функцию фильтра нижних частот и осуществляет подавление спекл-шума, о котором говорилось выше.

Однако если речь идет об автоматическом дешифровании снимка (интерпретация снимка человеком-оператором далеко не всегда возможна прежде всего из-за огромного объема обрабатываемой информации), то про процедуру подавления шума на изображении забывать нельзя.

Кроме того, при визуальном восприятии снимка в данном примере не учитывались требования к пространственному разрешению и/или уровню шума на изображении, которое обычно накладывается условиями тематической задачи.

Если попробовать оценить качество снимка с использованием количественных характеристик (что является обязательным элементом автоматического дешифрования), то можно заметить следующие эффекты:

1) ширина гистограммы распределения яркости на снимке становится тем уже, чем больше размер скользящего окна при фильтрации, а это означает, что уровень шума становится меньше,

2) на гистограммах обработанных снимков появляется второй максимум (и чем больше размер окна обработки, тем максимум виден отчетливее), а это означает, что в шумах присутствует (и можно обнаружить) объект, имеющий меньшую ЭПР по сравнению с преобладающей. Таким объектом в данном примере является водная поверхность (река).

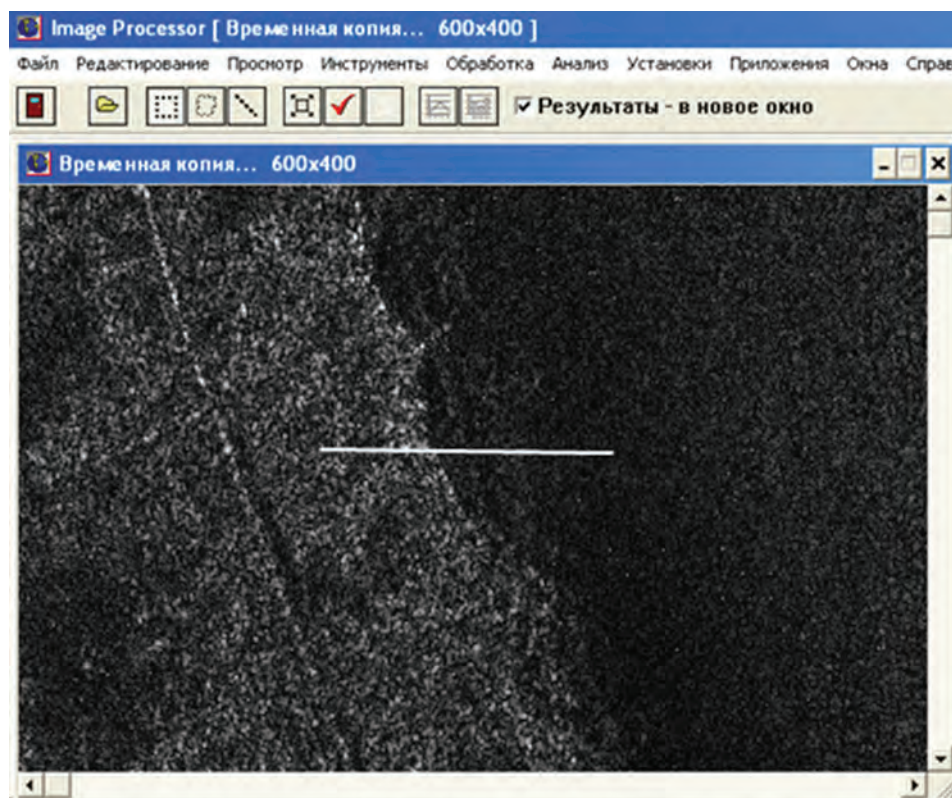


Рис. 10.17. Построение сечения РЛИ




Рис. 10.18. Сечение РЛИ до (а) и после обработки фильтром с размером «окна» обработки  $3 \times 3$  ((б) — усредняющий фильтр, (в) — медианный фильтр и (г) — фильтр Ли)




Рис. 10.19. Сечение РЛИ до (а) и после обработки фильтром с размером «окна» обработки  $7 \times 7$  ((б) – усредняющий фильтр, (в) – медианный фильтр и (г) – фильтр Ли)



Следовательно, если пространственное разрешение исходного снимка избыточно для решения поставленной задачи, то снижением уровня спекл-шума за счет ухудшения разрешения можно добиться значительного улучшения результата при автоматическом дешифровании снимка.

Нечто подобное можно наблюдать в следующем примере (рис. 10.17), где необходимо в заданном канале обнаружить границу «берег-море». На изображении белой линией отмечено положение яркостного среза (канала). Сечение, соответствующее данному срезу яркости показано на рис. 10.18, а и 10.19, а. Сечение построено в направлении, перпендикулярном траектории носителя РСА и имеет длину 250 отсчетов.

Даже опытному дешифровщику непросто определить присутствует ли на данном фрагменте граница «берег-море» или нет. Но уже на последующих рис. 10.18, б (10.19) – 10.18, г (10.19, г) эта граница просматривается довольно отчетливо.

На рис. 10.18, б (10.19) – 10.18, г (10.19, г) изображено то же сечение того же фрагмента РЛИ, но уже после его обработки усредняющим, медианным и фильтром Ли соответственно. И если на рис. 10.18 спекл-структура РЛИ еще просматривается, то на рис. 10.19 все пульсации сглажены довольно существенно. Это связано с тем, что в первом случае обработка проводилась «скользящим окном», размер которого  $3 \times 3$  отсчета, то во втором –  $7 \times 7$ .

Как видно из рис. 10.18–10.19, более эффективным в данном случае (с точки зрения фильтрации спекла) является усредняющий фильтр с размером «окна» обработки  $7 \times 7$  отсчетов. Но не следует забывать, что чем больше «окно» обработки, тем, ниже вычислительная эффективность алгоритма. Обработка в «окне» размером  $7 \times 7$  отсчетов происходит примерно в пять раз медленнее, чем в «окне»  $3 \times 3$ . Кроме того, при большем окне обработки сильнее размывается приграничная зона. Последнее снижает точность в определении местоположения границы областей с различной ЭПР (в данном случае – граница «берег – море»).

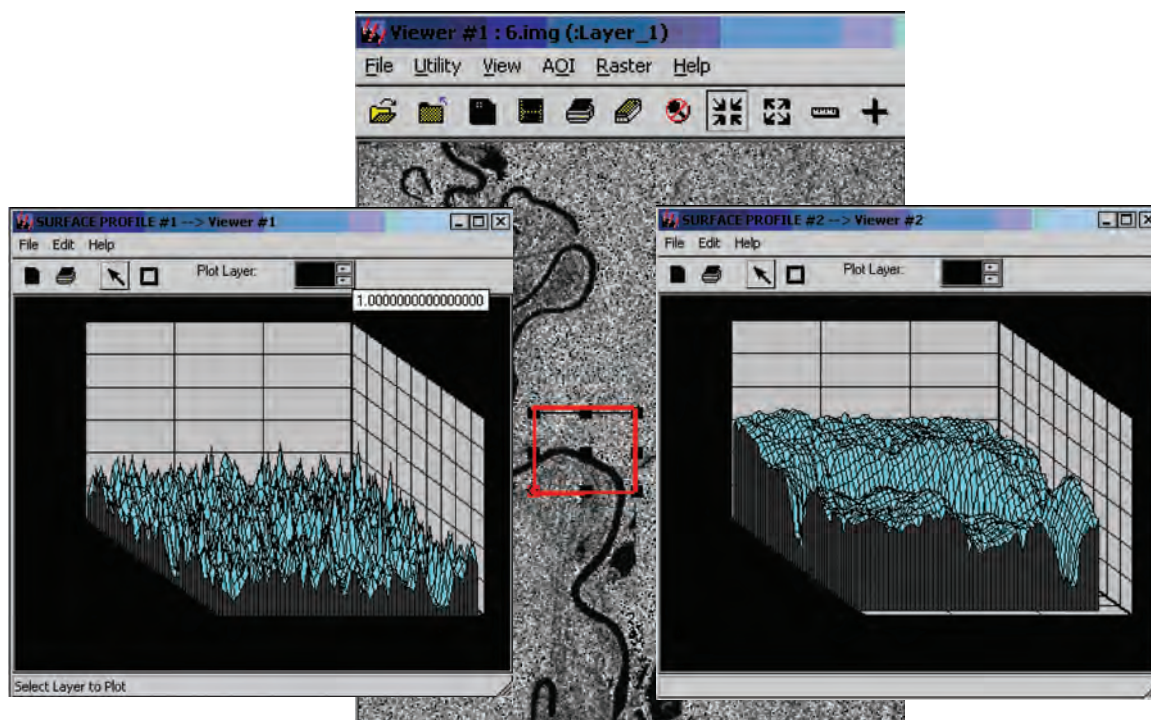


Рис. 10.20. Построение 3D-модели поверхности выделенного фрагмента изображения

То, что предварительная фильтрация шума оказывает существенную помощь при визуальном дешифровании снимка, можно наблюдать на рис. 10.20. В левом окне рисунка построена 3D-модель фрагмента, выделенная на изображении красным прямоугольником. По этой модели невозможно определить, что фрагмент изображения содержит руку. Этот же фрагмент изображения после фильтрации снимка методом Ли представлен в правом окне. На этой картинке отчетливо видна река и четко прослеживается ее русло.

### 10.7. Методика выбора фильтра и его параметров

Исследование алгоритмов фильтрации спекл-шума позволяет сделать вывод, что чем лучше сглаживается шум, тем хуже становится его пространственное разрешение снимка и тем больше вычислительные затраты. Таким образом, при выборе фильтрующей процедуры, а также ее параметров (например, размера окна обработки) необходимо искать компромиссное решение с учетом конкретно поставленной задачи [31].

Проиллюстрируем данное утверждение на конкретных примерах (вычислительные затраты учитывать не будем):

**Пример 1.** Необходимо уменьшить пятнистость РЛИ в два раза, сохранив, по возможности, пространственное разрешение снимка.

Как видно из табл. 10.4, условиям задачи удовлетворяют фильтры: усредняющий с размером окна  $3 \times 3$  отсчетов, медианный ( $3 \times 3$ ), Ли ( $3 \times 3$ ), локальный адаптивный ( $3 \times 3$ ) и сигма-фильтр ( $9 \times 9$ ). Данные фильтры ухудшают разрешение (табл. 10.5) в 2,07, 1,67, 1,82, 1,72 и 1,54 раза соответственно. Следовательно, лучшими фильтрами в исследуемом случае являются медианный и сигма-фильтры, худшим — усредняющий фильтр.

**Пример 2.** Условия задачи аналогичные, но требуется уменьшить пятнистость в 6 раз.

Требуемый уровень спекла обеспечивает усредняющий ( $5 \times 5$ ), Ли ( $7 \times 7$ ), медианный ( $9 \times 9$ ) и локальный адаптивный ( $9 \times 9$ ) фильтры. Сигма-фильтрацией за один проход такого уровня спекл-шума достичь не удастся. Размытие границы при этом составит 3,08, 3,00, 3,57, 3,91 соответственно. В данном случае лучшими являются усредняющий фильтр и фильтр Ли.

**Пример 3.** Требуется максимальным образом сгладить спекл-шум, однако пространственное разрешение при этом не должно ухудшаться более чем в три раза.

Второму условию удовлетворяют следующие фильтры: усредняющий ( $3 \times 3$ ), медианный ( $5 \times 5$ ), фильтр Ли ( $7 \times 7$ ) и локальный адаптивный фильтр ( $5 \times 5$ ), обеспечивая при этом уменьшение пятнистости в 3,03, 3,85, 6,25 и 3,71 раза. Следовательно, для данных условий задачи лучше всего подходит фильтр Ли, а худшим является усредняющий фильтр.

На описанных выше примерах была показана методика выбора процедуры фильтрации в зависимости от требований задачи. На практике же, кроме компромисса между уровнем спекл-шума и разрешением РЛИ (размытием границ), зачастую приходится учитывать вычислительные затраты на реализацию того или иного алгоритма, а также индивидуальные особенности последних. К ним относятся [5, 23, 31], например, стирание мелких деталей на изображении классическим медианным фильтром, ограниченный диапазон интенсивностей спекла, обрабатываемых локальным адаптивным фильтром, невозможность обеспечить сигма-фильтрацией требуемого уровня радиометрического разрешения и т. д.

В заключение отметим, что когда в задаче не сформулированы четкие требования к разрешению РЛИ, уровню спекл-шума на нем и т.д., для удобства дешифрования снимка выбор фильтрующей процедуры можно осуществлять, исходя из прогноза наблюдаемого сюжета (и решаемой задачи), так как поверхность, за которой производится наблюдение, может быть известна заранее на основании подспутниковых измерений или географических и других карт. Например, для мониторинга неоднородностей на морской поверхности наилучшим является усредняющий фильтр, для получения радиолокационных портретов кораблей или наблюдением за горной местностью предпочтение следует отдавать сигма-фильтру.

## 10.8. Литература к главе 10

1. Верба В.С., Неронский Л.Б., Осипов И.Г. и др. Радиолокационные системы земле-обзора космического базирования / под ред. В.С. Вербы. М.: Радиотехника, 2010. 680 с.
2. Кондратенков Г.С., Фролов А.Ю. Радиовидение. Радиолокационные системы дистанционного зондирования Земли / под ред. Г.С. Кондратенкова. М.: Радиотехника, 2005. 366 с.
3. Школьный Л.А., Толстов Е.Ф., Детков А.Н. и др. Радиолокационные системы воздушной разведки, дешифрование радиолокационных изображений / под ред. Л.А. Школьного. М.: Изд. ВВИА им. проф. Н.Е. Жуковского, 2008. 531 с.
4. Шовенгердт Р.А. Дистанционное зондирование. Модели и методы обработки изображений. М.: Техносфера, 2010. 560 с.
5. Воздушная разведка. Автоматизированное распознавание радиолокационных изображений. Монография / под ред. И.К. Антонова. М.: Радиотехника, 2021. 296 с.
6. Коберниченко В.Г. Радиоэлектронные системы дистанционного зондирования Земли. Екатеринбург: Изд-во Урал. ун-та, 2016. 220 с.
7. Lee J.-S. Statistical Modelling and Suppression of Speckle in Syntetic Aperture Radar Images // Proceedings of IGARSS'87 – International Geoscience and Remote Sensing Symposium. Ann Arbor. May 18-21 1987. New York, Institute of Electrical and Electronics Engineers, Volume 2 (A87-53101 24-43). p. 1331-1339.
8. Kasischke E.S., Maffett A.L., Larson R.W. Statistical Modelling of Intensity Distributions on Airborne SAR Imagery // Proceedings of IGARSS'87 – International Geoscience and Remote Sensing Symposium. Ann Arbor. May 18-21 1987. New York, Institute of Electrical and Electronics Engineers, Volume 2 (A87-53101 24-43). p. 1357-1362.
9. Ахметьянов В.Р. Обработка радиолокационных изображений в задачах дистанционного зондирования земли // Зарубежная радиоэлектроника. 1987. № 1. С. 70-81.
10. Белокуров А.А. Методы сглаживания спекл-шума на радиолокационных изображениях земной поверхности // Зарубежная радиоэлектроника. 1990. № 6. С. 26-35.
11. Аковецкий В.И., Донсков Г.Н., Корнеев Ю.Н., Неронский Л.Б. Радиолокационная фотограмметрия. М.: Недра, 1979. 239 с.
12. Фалькович С.Е., Пономарев В.И., Шварко Ю.В. Оптимальный прием пространственно-временных сигналов в радиолокаторах с рассеянием. М.: Радио и связь, 1989. 296 с.
13. Справочник по радиолокации / под ред. М.И. Сколника; пер. с англ. под общ. ред. В.С. Вербы: в 2 кн. М.: Техносфера, 2015 1352 с.
14. Штагер Е.А. Рассеяние радиоволн на телах сложной формы М.: Радио и связь, 1986. 184 с.

15. Волков А.В., Коберниченко В.Г. Алгоритмы цифрового моделирования процесса обработки сигналов от протяженных целей в РЛС с синтезированной апертурой // Проблемы повышения эффективности и качества радиотехнических систем. Межвуз. Свердловск: УПИ, 1980. С. 111-116.
16. Тихонов В.И. Статистическая радиотехника. М.: Радио и связь, 1982. 624 с.
17. Школьный Л.А., Глазков С.Л. Математическая модель и статистические характеристики спекл-структур радиолокационных изображений, получаемых радиолокаторами с синтезированной апертурой // Радиотехника. 1990. № 2. С. 3-8.
18. Grims T.R. Geometric Filter for Speckle Reduction / T.R. Grims // Applied Optics. 1985. Vol. 27. № 10.
19. Иванов О.Ю., Зраенко С.М. Оценка оптимальных параметров системы обработки сигналов в РСА по реальным РЛИ. Методические указания к лабораторной работе. Екатеринбург: Изд-во Урал. ун-та, 2005. 28 с.
20. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА, формируемых в РСА. Монография. М.: Издательский дом Академии Естествознания, 2017. 212с.
21. Ivanov O.J. Kobernichenko V.G. Processing of coherent radar images of space remote sensing // X International Scientific-Research Conference "Radiolocation, Navigation, Communication". Voronezh, 2004. V. 3, P. 154–161.
22. Иванов О.Ю. Коберниченко В.Г., Зайцев В.В. Программно-алгоритмическое обеспечение для обработки данных космического радиолокационного мониторинга широким кругом пользователей // Труды международного симпозиума «Методы и средства мониторинга состояния окружающей среды. МСОС–95». С.-Петербург, 1995.
23. Прэтт У. Цифровая обработка изображений. М.: Мир, 1982. 792 с.
24. Ваи Трис Г. Теория обнаружения, оценок и модуляции. Том I. / пер. с англ. под ред. В.Т. Горяинова. М.: Сов. Радио, 1977. 662 с.
25. Василенко Г.И. Тараторин А.М. Восстановление изображений. М.: Радио и связь, 1986. 304 с.
26. Porcello L.J. Massey N.G., Innes B.B., Marks J.M. Speckle Reduction in Synthetic Aperture Radar // Optical Society of America. 1976. Vol. 66. № 11.
27. Никольский Д.Б. Сравнительный обзор современных радиолокационных систем // Геоматика, № 1. 2008. С.11-17
28. Nathan K.S., Curlander J.C. Speckle Noise Reduction of 1-Look SAR // Proceedings of IGARSS'87 – International Geoscience and Remote Sensing Symposium. Ann Arbor. May 18-21 1987. New York, Institute of Electrical and Electronics Engineers, Volume 2 (A87-53101 24-43). p. 1437-1442.
29. Lee J.-S. Speckle Analysis and Smoothing of Synthetic Aperture Radar Images // Computer Graphics and Image Processing. 1981. № 17.
30. Frost V.S. Stiles J.A., Holtzman J.C. Radar Image Processing // Machine Processing of Remotely Sensed Data Symposium. 1980.
31. Старовойтов В.В. Методика выбора фильтра для сглаживания спекл-шума радарных изображений с синтезированной апертурой // Информатика, № 2. 2015. С. 5-11
32. Ivanov O.Y., Sosnovsky A.V. Modification of the Frost Speckle-Noise Filter for Solving Problems of Radar Data Processing. // Proceedings International Conference on Numerical Analysis and Applied Mathematics, ICNAAM 2019. November 24 2019. American Institute of Physics Inc., 140007. (AIP Conference Proceedings; Volume 2293).



## 11. АНАЛИЗ ПОМЕХОУСТОЙЧИВОСТИ РЛС С СИНТЕЗИРОВАННОЙ АПЕРТУРОЙ

Эффективное решение задачи обнаружения и, тем более, распознавания объектов, расположенных на земной (водной) поверхности, средствами радиолокационного наблюдения с синтезированной апертурой [1] требует обеспечения достаточно высокого (порядка 20 дБ) [2] отношения сигнал/шум. В тоже время следует иметь в виду, что при наблюдении земли из космоса возможно действие искусственных помех, как специально организованных, так и связанных с работой различных радиотехнических средств. Последнее обстоятельство стимулирует решение задачи анализа влияния такого рода помех и разработки методики расчета помехозащищенности РСА с тем, чтобы оценить возможность эффективного решения задач классификации в реальной помеховой обстановке.

### 11.1. Вывод основных соотношений

Рассмотрим процесс наблюдения точечной цели с помощью бистатической РСА при наличии в зоне действия РЛС совокупности  $N_{\Pi}$  точечных источников шумовых помех. Геометрические соотношения, характеризующие указанную ситуацию, приведены на рис. 11.1. Определим отношения сигнал/помеха и сигнал/(помеха + шум) в элементе РЛИ.




Рис. 11.1. Геометрические соотношения



Комплексная амплитуда сигнала, принимаемого в  $n$ -м периоде повторения зондирующих импульсов, может быть представлена в виде:

$$U(n, t) = U_0 G(\bar{x}_u, t_n) S_n(\bar{x}_u, t) E(\bar{x}_u, t_n) f_u + N(t) + \sum_{i=1}^{N_{\Pi}} U_i G_2(\bar{x}_{ui}, t_n) S_i^{\Pi} \left[ t - \frac{r_2(\bar{x}_{ui}, t_n)}{C} \right] E_2(\bar{x}_{ui}, t_n) g_i^{\Pi}(t_n), \quad (11.1)$$

где  $f_u$  — значение комплексной функции отражения для наблюдаемой точечной цели,

$$0,5 f_u^* f_u = 1; \quad (11.2)$$

$$S_n(\bar{x}_u, t) = S \left\{ t - nT - \left[ r_1(\bar{x}_u, t) + r_2(\bar{x}_u, t) \right] J/c \right\} \quad (11.3)$$

— комплексная огибающая  $n$ -го зондирующего импульса;  $\bar{x}$  — радиус-вектор, задающий положение наблюдаемой точки;  $g_i^{\Pi}(t_n)$  — значение нормированной диаграммы направленности излучающей системы  $i$ -го источника помех в направлении приемной антенны РЛС в  $n$ -м периоде зондирования;  $S_i^{\Pi}(t)$  — комплексная амплитуда колебания, излученного  $i$ -м источником помех;

$$G_2(\bar{x}, t_n) = \frac{q_2(\bar{x}, t_n)}{r_2(\bar{x}, t_n)}; \quad (11.4)$$

$$E_2(\bar{x}, t_n) = \exp \left[ -jkr_2(\bar{x}, t_n) \right]; \quad (11.5)$$

$$G(x, t) = \frac{q_1(\bar{x}, t_n) q_2(\bar{x}, t_n)}{r_1(\bar{x}, t_n) r_2(\bar{x}, t_n)}; \quad (11.6)$$

$$E(\bar{x}, t_n) = \exp \left\{ -jk \left[ r_1(\bar{x}, t_n) + r_2(\bar{x}, t_n) \right] \right\}, \quad (11.7)$$

где  $q_1(\bar{x}, t_n)$ ,  $q_2(\bar{x}, t_n)$  — значения нормированных диаграмм направленности антенн приемника и передатчика РЛС в направлении точки  $\bar{x}$  до передатчика и приемника РЛС в момент излучения  $n$ -го импульса;

$$U_i = \sqrt{\frac{G_{20} G_i^{\Pi} \lambda_0^2}{(4\pi)^2}}; \quad (11.8)$$

$$U_o = \sqrt{\frac{2P_0 \lambda^2 G_{10} G_{20}}{(4\pi)^3} \sigma_u^2}, \quad (11.9)$$

где  $G_{i0}^{\Pi}$  — коэффициент усиления излучающей системы  $i$ -го источника помех;  $G_{10}$ ,  $G_{20}$  — коэффициенты усиления передающей и приемной антенн РЛС;  $P_0$  — импульсная мощность зондирующего сигнала;  $\sigma_u^2$  — ЭПР цели. В дальнейшем для сокращения записей вместо « $t_n$ » используется обозначение « $n$ ».

При формировании РЛИ принимаемый сигнал проходит через фильтр, согласованный с одиночным зондирующим импульсом. На выходе фильтра в  $j$ -м канале дальности и  $n$ -м периоде повторения получаем отсчет, величина которого определяется выражением:

$$U_j(n) = \int U(n, t) S_{\Pi}^*(\bar{x}_{oj}, t) dt, \quad (11.10)$$

где  $\bar{x}_{oj}$  — радиус-вектор, задающий положение  $j$ -го канала дальности в пространстве.

При формировании РЛИ методом весового суммирования для  $k$ -го азимутального отсчета в  $j$ -м канале дальности получаем выражение:

$$F_j(k) = \sum_{n=-M}^M U_j(k+n) H_j(n), \quad (11.11)$$

где  $H_j(n)$  — комплексная весовая функция обработки для  $j$ -го канала дальности;  $2M+1$  — число когерентно суммируемых импульсов.

После подстановки (10) в (11) с учётом (11.1) запишем выражения для сигнальной  $F_{jc}$ , помеховой  $F_{jn}$  и шумовой  $F_{ju}$  составляющих  $k$ -го отсчета РЛИ в  $j$ -м канале:

$$F_{jc}(k) = U_o f_u \Psi^D(\bar{x}_{Oj}, \bar{x}_u) \sum_{n=-M}^M G[\bar{x}_u, (n+k)] E[\bar{x}_u, (n+k)] H_j(n); \quad (11.12)$$

$$F_{jn}(k) = \sum_{i=1}^{N_n} U_i \sum_{n=-M}^M G_2[\bar{x}_{ni}, (n+k)] E_2[\bar{x}_{ni}, (n+k)] g_i^n(n+k) H_j(n) \times \\ \times \int_0^* S_{n+k}(\bar{x}_{Oj}, t) S_i^n \{e - r_2[\bar{x}_{ni}, (n+k)]/c\} dt; \quad (11.13)$$

$$F_{ju}(k) = \sum_{n=-M}^M H_j(n) \int_0^* S_{n+k}(\bar{x}_{Oj}, t) N(t) dt, \quad (11.14)$$

где  $\Psi^D(\bar{x}_{Oj}, \bar{x}_u)$  — функция неопределенности одиночного зондирующего импульса.

Определим дисперсии полученных величин (11.12)–(11.14).

$$\sigma_{jc}^2(k) = U_o^2 \left| \Psi^D(\bar{x}_{Oj}, \bar{x}_u) \right|^2 \left| \sum_{n=-M}^M G[\bar{x}_u, (n+k)] E[\bar{x}_u, (n+k)] H_j(n) \right|^2; \quad (11.15)$$

$$\sigma_{jn}^2(k) = \sum_{i=1}^{N_n} U_i^2 \sum_{n=-M}^M \sum_{m=-M}^M G_2[\bar{x}_{ni}, (n+k)] E_2[\bar{x}_{ni}, (n+k)] g_i^n(n+k) H_j(n) \times \\ \times p_{ij}^\Phi[(n+k), (m+k)] G_2[\bar{x}_{ni}, (m+k)] E_2[\bar{x}_{ni}, (m+k)] g_i^m(m+k) H_j(m), \quad (11.16)$$

$$\text{где } p_{ij}^\Phi(n, m) = \iint p_i \left\{ [t - r_2(\bar{x}_{ni}, n)/c], [u - r_2(\bar{x}_{ni}, m)/c] \right\} S_i^n(\bar{x}_{Oj}, t) S_i^m(\bar{x}_{Oj}, u) dt du \quad (11.17)$$

— коэффициент корреляции  $n$ -го и  $m$ -го отсчетов помехи, излученной  $i$ -м источником, на выходе фильтра в  $j$ -м канале дальности;

$$p(t, u) = 0,5 S_i^n(t) S_i^m(u) \quad (11.18)$$

— корреляционная функция колебаний  $i$ -го источника помех.

Для широкополосных помех, имеющих спектральную плотность  $N_i$ , справедливы выражения:

$$p_i(t, u) = N_i \delta(t - u); \\ p_{ij}^\Phi(n, m) = \Psi^D(\bar{x}_{Oj}, \bar{x}_{Oj}) N_i, \quad (11.19)$$

где  $\delta_{nm}$  — символ Кронеккера. При этих условиях выражение (11.16) принимает следующий вид:

$$\sigma_{jn}^2(k) = \sum_{i=1}^{N_n} N_i \Psi^D(\bar{x}_{Oj}, \bar{x}_{Oj}) U_i^2 \sum_{n=-M}^M \left\{ G_2[\bar{x}_{ni}, (n+k)] g_i^n(n+k) H_j(n) \right\}^2. \quad (11.20)$$

Полагая шум «белым» со спектральной плотностью  $N_o$ , для дисперсии шумовой составляющей получим:

$$\sigma_{jш}^2(k) = N_o \Psi^D(\bar{x}_{oj}, \bar{x}_{oj}) \sum_{n=-M}^M |H_j(n)|^2. \quad (11.21)$$

Искомые отношения сигнал/помеха ( $q_{сн}$ ) и сигнал/(помеха + шум) ( $q_{сшш}$ ) в  $j$ -м канале дальности определяются следующим образом:

$$q_{сн}(j, k) = \sigma_{jc}^2(k) / \sigma_{jш}^2(k); \quad (11.22)$$

$$q_{сшш}(j, k) = \sigma_{jc}^2(k) / [\sigma_{jш}^2(k) + \sigma_{jc}^2(k)] = [1/q_{сн}(j, k) + 1/q_{сш}(j, k)]^{-1}, \quad (11.23)$$

где 
$$q_{сш}(j, k) = \sigma_{jc}^2(k) / \sigma_{jш}^2(k) \quad (11.24)$$

– отношение сигнал/шум на выходе РСА.

Зависимость отношений  $q_{сн}$ ,  $q_{сшш}$  и  $q_{сш}$  от « $j$ » и « $k$ » характеризует их изменение при переходе от одного элемента РЛИ к другому.

Для определения коэффициента улучшения и зон подавления рассмотрим следующие соотношения:

$$q_{oi}(k) = \frac{U_o^2 \Psi^D(\bar{x}_{oj}, \bar{x}_{oj})}{U_i^2 N_i r_i^2(x_{ц}, k)}; \quad (11.25)$$

$$q_{ош}(k) = \frac{U_o^2 \Psi^D(\bar{x}_{oj}, \bar{x}_{oj})}{N_o r_1^2(x_{ц}, k) r_2^2(x_{ц}, k)}. \quad (11.26)$$

Для функции неопределенности одиночного импульса длительностью  $\tau_{и}$  справедливо равенство

$$\Psi^D(\bar{x}, \bar{x}) = \tau_{и}. \quad (11.27)$$

Выражение (11.25) с учётом (11.8) и (11.9) представляет собой отношение энергии сигнала к спектральной плотности  $i$ -й помехи на входе приёмника РЛС в  $k$ -м периоде зондирующих импульсов для случая, когда  $i$  –  $q$  источник помех находится в той же точке пространства, что и цель

Используя введенные обозначения (11.25) и (11.26), для широкополосных помех формулы (11.22) и (11.24) можно представить в следующем виде:

$$q_{сн}(j, k) = \left[ \sum_{i=1}^{N_{п}} \frac{1}{q_{oi}(k) K_{yi}(j, k)} \right]^{-1}; \quad (11.28)$$

$$q_{сш}(j, k) = (k) K_{ш}(j, k), \quad (11.29)$$

где 
$$K_{yi}(j, k) = \frac{r_1^2(\bar{x}_{ц}, k) \left| \sum_{n=-M}^M G[\bar{x}_{ц}, (n+k)] E[\bar{x}_{ц}, (n+k)] H_j(n) \right|^2}{\sum_{n=-M}^M \left\{ G[\bar{x}_{ш}, (n+k)] g_i^n(n+k) \right| H_j(n) \right|^2}; \quad (11.30)$$

$$K_{ш}(j, k) = \frac{r_1^2(\bar{x}_{ц}, k) r_2^2(\bar{x}_{ц}, k)}{\sum_{n=-M}^M |H_j(n)|^2} \left| \sum_{n=-M}^M G[\bar{x}_{ц}, (n+k)] E[\bar{x}_{ц}, (n+k)] H_j(n) \right|^2. \quad (11.31)$$

Как следует из (11.29), коэффициент  $K_{ш}$  имеет смысл коэффициента улучшения отношения сигнал/шум за счет когерентного накопления в устройстве синтеза. Для выяснения смысла коэффициента  $K_{yi}$  рассмотрим случай воздействия на РСА одиночного источника помех. При этом имеем:

$$q_{сн}(j,k) = q_{oi}(k)K_{yi}(j,k). \quad (11.32)$$

Это выражение позволяет трактовать введенный безразмерный коэффициент как коэффициент улучшения отношения сигнал/(одиночная точечная помеха) за счет синтеза апертуры. Для РСА с заданными характеристиками  $K_{yi}$  зависит только от взаимного расположения цели, источника помех и участка синтеза. Независимость введенного коэффициента от энергетических параметров РЛС и источника помех делает его удобной характеристикой для сравнения различных вариантов построения РСА по их помехозащищенности.

При воздействии на РСА узкополосных помех коэффициент улучшения отношения сигнал/помеха может быть записан следующим образом:

$$K_{yi}(j,k) = r_1^2(\bar{x}_u, k) \left| \sum_{n=-M}^M G[\bar{x}_u, (n+k)] E[\bar{x}_u, (n+k)] H_j(n) \right|^2 \times \\ \times \left\{ \sum_{n=-M}^M \sum_{m=-M}^M G_2[\bar{x}_{ni}, (n+k)] E_2[\bar{x}_{ni}, (n+k)] g_i^n(n+k) H_j(n) \times \right. \quad (11.33) \\ \left. \times p_{ij}^{ФН}[(n+k), (m+k)] G[\bar{x}_i, (m+k)] E^*[\bar{x}_{ni}, (m+k)] g_i^n(m+k) H_j^*(m) \right\}^{-1},$$

где  $p_{ij}^{ФН}(n, m)$  — нормированный к максимальному значению коэффициент корреляции  $n$ -го и  $m$ -го отсчетов  $i$ -й помехи на выходе фильтра в  $j$ -м канале дальности.

Для наглядного представления о работоспособности РСА в условиях помех могут быть использованы, так называемые, зоны подавления, которые представляют собой области поверхности, отвечающие следующему условию — при расположении источника помехи в пределах названной зоны отношение сигнал/помеха не превышает заданного уровня.

Полученные результаты — выражения для расчета помехозащищенности — позволяют проводить анализ эффективности конкретных вариантов построения РСА.

## 11.2. Расчёт зон подавления и коэффициентов улучшения

Рассмотрим типовой случай использования. Приемная и передающая РЛС расположены на одном носителе, причем диаграммы направленности (ДН) антенн ориентированы по нормали к траектории носителя (азимутальный скос ДН отсутствует). Все приведенные ниже результаты анализа помехозащищенности получены применительно к РЛС типа SEASAT-A, основные параметры которой имеют следующие значения:

- высота полета носителя РЛС — 800 км;
- скорость носителя — 7500 м/с;
- период повторения зондирующих импульсов —  $0.6 \cdot 10^{-3}$  с;
- длина волны излучения — 23,5 см;
- горизонтальный раскрыв антенны — 11 м;

- угол наклона луча антенны к вертикали –  $20^\circ$ ;
- импульсная мощность передатчика – 800 Вт;
- полоса частот приемного тракта – 6 МГц;
- коэффициент сжатия – 642.

При фокусированной обработке когерентно суммируются 1025 отсчетов сигнала в каждом канале дальности, что соответствует участку синтезирования длиной 4612,5 метров и времени накопления 0,615 с. Разрешение по азимуту в этом случае составляет около 22 м. Для нефокусированной РСА участок синтезирования определяется следующим образом:

$$L_{эфф} = \sqrt{(H^2 + R_o^2)}\lambda, \quad (11.34)$$

где  $H$  – высота полета носителя;  $R_o$  – горизонтальная дальность до точки наблюдения;  $\lambda$  – длина волны.

При выбранных параметрах  $L_{эфф} = 447,3$  м, что соответствует накоплению 101 отсчета и разрешению 224 м.

Сравнение помехоустойчивости фокусированных и нефокусированных РСА производилось на основе зависимости коэффициента улучшения  $K_y$  от координат точечного источника помехи относительно точки нахождения цели. На рис. 11.2 представлены зоны подавления РСА, соответствующие зависимости коэффициента улучшения от положения источника помех.




Рис. 11.2. Пример построения зоны подавления РСА одиночным источником помех (заштрихованы области, где  $K_y < 50$  дБ)

Анализ полученных результатов позволяет сделать следующие выводы.

1. Зависимость коэффициента улучшения отношения сигнал/помеха от азимутального положения источника помех носит сложный лепестковый характер. Вид названной зависимости в основном определяется формой диаграммы направленности антенны РЛС в азимутальной плоскости и характером движения РЛС.

2. При увеличении количества суммируемых отсчетов в зависимости коэффициента улучшения от азимута постановщика помех провалы характеристик уменьшаются, а пики сглаживаются.



3. Использование фокусированных РСА, как и следовало ожидать, обеспечивает дополнительный выигрыш в помехозащищенности по сравнению с нефокусированной РСА. В рассмотренных примерах помехозащищенность фокусированных РСА примерно на порядок выше.

4. Для эффективного обнаружения сигнала со случайными амплитудами и фазами (вероятность правильного обнаружения порядка 0.9 при вероятности ложной тревоги  $10^{-6}$ ) следует обеспечить отношение сигнал/помеха порядка 20 дБ. Диапазон изменения отношения сигнал/помеха при действии типовых источников при значении ЭПР, составляющей 104–105 м<sup>2</sup>, отношение сигнал/помеха на выходе линейной части приемника изменяется от –25 до –72 дБ (в зависимости от типа постановщика). Следовательно, для обнаружения цели необходимо обеспечить коэффициент улучшения от 45 до 95 дБ. Из рис. 11.3 и 11.4 видно, что нижняя граница для РЛС с ДН вида  $\frac{\cos x}{1 - \left(\frac{2}{\pi}x\right)^2}$  при нефокусированной РСА достигается при удалении источника помехи

от цели не менее 39 км по азимуту. В фокусированной РСА эта граница составляет не менее 22 км. Достижение верхней границы возможно при удалении постановщика помехи на расстояние не менее 100 км. Таким образом, для обеспечения эффективного функционирования при действии организованных помех необходимо использовать специальные методы защиты от помех (пространственная селекция с помощью ФАР, применение адаптивных компенсаторов и т. п.).




Рис. 11.3. Зависимость коэффициента улучшения от азимутальной координаты источника помехи для нефокусированной РСА при различных аппроксимациях ДН антенны РЛС




Рис. 11.4. Зависимость коэффициента улучшения от азимутальной координаты источника помехи для фокусированной РСА при различных аппроксимациях ДН антенны РЛС

Рассмотрим воздействие на РСА группы помех, включающих два постановщика. На рис. 11.5 и 11.6 приведены зависимости нормированного отношения сигнал/помеха на выходе нефокусированной РСА для одиночного источника помехи и группы из двух одинаковых источников. Графики нормированы к отношению сигнал/помеха на входе РСА для случая, когда цель и центр источника помехи расположены в одной точке пространства.




Рис. 11.5. Зависимость коэффициента улучшения от азимута (— некоррелированная помеха, — — — коррелированная помеха)




Рис. 11.6. Зависимость нормированного отношения сигнал/помеха на выходе нефокусированной РСА от азимутального разнеса между целью и источником помех

При этом зависимость для одного источника помехи совпадает с графиком коэффициента улучшения, а для группового источника получаем:

$$q_n = \left[ \sum_j \frac{1}{K_{yi}} \right]^{-1}. \quad (11.35)$$

Вдоль оси абсцисс на графиках отложена азимутальная координата центра группы постановщиков помех. Параметр  $\Delta x$  на всех графиках представляет собой расстояние между источниками помех. В силу симметрии рисунков от абсциссы графика приведены зависимости только для отрицательных значений азимута. ДН антенны аппроксимирована зависимостью вида  $\frac{\sin x}{x}$ . Анализ полученных результатов позволяет сделать следующие выводы.

1. Воздействие источников помех, разнесенных по азимуту на расстояние, не превышающее половины ширины главного лепестка, выраженной в линейных единицах на «высвечиваемой» поверхности, приводит:

- к ухудшению отношения сигнал/помеха на выходе РСА по сравнению со случаем использования одиночного источника;
- к сглаживанию пиков зависимости отношения сигнал/помеха от азимутальной координаты источника;
- к сдвигу экстремумов зависимости в направлении возрастания абсолютного значения азимута.

2. В случае воздействия источников помех, разнесенных по азимуту более, чем на половину ширины ДН РЛС, в зависимости от отношения сигнал/помеха на выходе РСА наблюдаются два равных, явно выраженных минимума, которые раздвигаются с ростом расстояния между источниками помех в группе.

### 11.3. Литература к главе 11

1. Верба В.С. Авиационные комплексы радиолокационного дозора и наведения. Состояние и тенденции развития. — Радиотехника. — 2008. — 432с.
2. Dorosinskiy L.G., Kurgaysky A.A. Signal Detection in SAR Against the clutter reflections Background. 7-th International Conference on Modeling, Simulation and Applied Optimization, ICMSAO 217. April 4-6, 2017, Sharjah, United Arab Emirates.

## 12. ГЕОКОРРЕКЦИЯ ИЗОБРАЖЕНИЙ

Изображения, полученные при помощи различных сенсоров, установленных на спутниках или самолетах, являются, как правило, отображением неровной земной поверхности на плоскости. Даже изображения плоской территории несут в себе искажения. Геометрическими искажениями изображения называются различия между координатами и размерами реального изображения и идеального. Причин появления искажений множество. Это и особенности оборудования, используемого при съемке, и нестабильность траектории летательного аппарата, и необходимость получения снимка в заданной проекции и т.д. [1–5]. Кроме того, следует отметить, что все эти причины действуют совместно

Наличие геометрических искажений существенно затрудняют успешное решение большинства прикладных задач (где используются данные ДЗЗ), таких как;

- выполнение точных измерений расстояний и площадей,
  - формирование обучающих выборок по их картографическим координатам для выполнения классификации объектов изображения,
  - сравнение двух изображений,
  - монтаж изображений (мозаика).
  - привязка изображений или объектов съемки к электронной карте местности,
  - наложение векторных данных на изображение,
  - создание геоинформационных баз данных для ГИС-моделирования
- и др.

Чтобы обеспечить метрическую достоверность и картографическую привлекательность полученного снимка и его сопоставимость с другими необходимо устранить искажения, возникшие в процессе съемки. Процесс исправления ошибок, возникших в относительном расположении пикселей, осуществляется при помощи геометрической коррекции снимка.

Геокоррекция – это процесс преобразования данных, обеспечивающий переход от одной сетки координат к другой с помощью некоторого геометрического преобразования. Геометрическая коррекция включает в себя: устранение на изображении геометрических искажений и его графическую привязку.

В данной главе описаны методы трансформирования изображения (геокоррекции) на основе полиномов и триангуляции. Другие методы трансформирования приведены в работах Йенга [11–13].

### 12.1. Причины появления геометрических искажений

Как было отмечено выше, неотъемлемой частью изображений, получаемых от различных систем дистанционного зондирования Земли, являются геометрические искажения. Причины этих искажений различны (рис. 12.1).

Из всего представленного на рисунке многообразия можно выделить две основных группы искажений. Первая группа – это искажения, обусловленные самим процессом съемки (кривизна Земли, особенности съемочных систем и др.), вторая – искажения, получающиеся при привязке снимка к цифровой карте местности или другому снимку.

Рассмотрим подробнее основные (наиболее часто встречающиеся на практике) искажения снимков и их причины.

На рисунке отчетливо просматриваются два нежелательных явления — затенение и инверсия. Так как точки сканируемой местности не лежат в одной плоскости (это особенно проявляется в горной местности) и наблюдение ведется под углом к поверхности Земли, то высокие объекты (рис. 12.2, точка 2) закрывают часть пространства за ними [7, 14].



Рис. 12.1. Источники искажений на снимках

Рисунок 12.2 иллюстрирует возможные искажения, которые могут возникнуть в РЛС бокового обзора.




Рис. 12.2. Эффект инверсии

Эффект инверсии переднего склона заключается в том, что из-за сферичности фронта электромагнитной волны, излучаемой локатором, точка 2 (рис. 12.2) будет располагаться на месте точки 2', и отклик от точек 1, 2, 3 будет получен в следующем порядке — 2'', 1'', 3''.



Для оптоэлектронных сенсоров, даже если съемка ведется строго в нади́р, также характерны специфические искажения. Вследствие того, что камера имеет линзу ограниченного размера и толщина линзы непостоянна, на краях снимка и в его центре возникающие искажения неодинаковы. Наблюдается явление дисторсии, при котором коэффициент линейного увеличения изменяется по полю зрения. Это приводит к нарушению подобия между объектом и его изображением. Прямые линии, в результате, изображаются кривыми, кроме тех, которые лежат в одной плоскости с оптической осью. Например, изображение квадрата, центр которого пересекает оптическая ось, может выглядеть по-разному (рис. 12.3). Оно может принимать вид «подушки» (подушкообразная дисторсия) при положительной дисторсии, и вид «бочки» (бочкообразная дисторсия) – при отрицательной. Существуют и другие, более сложные искажения формы [16].




Рис. 12.3. Идеальное изображение, «подушка» и «бочка»

Неизбежным источником искажения является также тот факт, что датчик, установленный на космическом носителе, формирует изображение, стороны которого ориентированы вдоль и поперек линии пути носителя, и, как правило, не совпадающей с общепринятыми направлениями Север-Юг или Запад-Восток. Поэтому возникает необходимость в повороте полученного кадра [6].

Еще одной причиной искажений может стать несоответствием формата изображения той или иной картографической проекции (рис. 12.4).



Рис. 12.4. Классификация картографических проекций

Самыми распространенными географическими системами координат для территории России являются [17, 18]:

- универсальная общеземная система WGS-84 (World Geodetic System-1984), базирующаяся на эллипсоиде WGS-84 с центром в центре масс Земли. Система широко применяется за рубежом, ее используют практически для всех данных, производимых в мире;
- референсная Pulkovo-1942 (СК-42), базирующаяся на эллипсоиде Красовского, начало координат смещено относительно центра масс на расстояние около 100 м (поэтому эта система и носит название референцной, или относительной). Система используется в России и некоторых окружающих странах.

Объекты на карте связаны с реальными объектами на местности с помощью пространственных координат. Местоположение объектов на поверхности Земли определяется при помощи географических координат — широты и долготы.

Хотя географические координаты хорошо подходят для определения местоположения объекта, они не всегда удобны для определения его пространственных характеристик, таких как длина, площадь и т. д. Для преодоления этих трудностей данные переводят из сферических географических координат, в прямоугольные спроецированные координаты.

Картографическая проекция — математически определенный способ отображения поверхности эллипсоида на плоскости. Суть проекций заключается в том, чтобы фигуру Земли — эллипсоид, не развёртываемый в плоскость — заменить другой фигурой, развёртываемой на плоскость, или непосредственно плоскостью.

По типу поверхности, на которую осуществляется проецирование, проекции разделяются на:

- конические — проецирование сфероида на коническую поверхность;
- цилиндрические — проецирование сфероида на цилиндрическую поверхность;
- азимутальные — проецирование сфероида на плоскость касательную сфероиду.

Рисунок 12.5 иллюстрирует принципы получения различных видов картографических проекций.




Рис. 12.5. Различные виды проекций

По характеру искажений, вносимых в содержание изображения после его проецирования, проекции делятся на:

- равноплощадные (равновеликие) — отсутствуют искажения площадей;
- равноугольные — отсутствуют искажения углов и, следовательно, формы объектов;
- равнопромежуточные — отсутствуют искажения длин — расстояния остаются неизменными в определенных направлениях.

Существуют также проекции, в которых искажения минимизированы сразу по двум или трем показателям (углы, длины, площади).

Проекций, в которых сохранялся бы масштаб длин во всех направлениях, не существует.

Наиболее широко в мире распространены группы проекций UTM (Universal Transverse Mercator) и ГК (Гаусса-Крюгера). Последняя наибольшее распространение получила в России и странах Восточной Европы. Обе этих группы базируются на одной поперечной проекции Меркатора (Transverse Mercator), однако имеют различную номенклатуру и параметры проекций для каждой зоны.

Воображаемый цилиндр, на который происходит проецирование в вышеупомянутых случаях, охватывает земной эллипсоид по меридиану, называемому центральным (осевым) меридианом зоны. Зона — это участок земной поверхности, ограниченный двумя меридианами. Обе проекции делят земной эллипсоид на 60 зон шириной  $6^\circ$ . Зоны нумеруются с запада на восток, начиная с  $0^\circ$ . Зона 1 простирается с меридиана  $0^\circ$  до меридиана  $6^\circ$ , ее центральный меридиан  $3^\circ$ . Зона 2 — с  $6^\circ$  до  $12^\circ$  и т.д.

Таким образом, для данной долготы номер зоны определяется как целая часть от деления долготы на  $6^\circ$  плюс 1, а центральный меридиан равен (номер зоны)  $\times 6^\circ$  минус  $3^\circ$ .

В проекции Гаусса-Крюгера цилиндр касается эллипсоида по центральному меридиану, масштаб вдоль него равен 1 (рис. 12.6).



Рис. 12.6. Принцип проекции Гаусса-Крюгера

UTM — это проекция на секущий цилиндр и масштаб равен единице вдоль двух секущих линий, отстоящих от центрального меридиана на 180 000 м (рис. 12.7).




Рис. 12.7. Принцип проекции UTM

## 12.2. Методы коррекции геометрических искажений

Геометрическая коррекция снимков позволяет решить сразу несколько задач.

Во-первых, в результате коррекции устраняются, или, по крайней мере, существенно уменьшаются геометрические искажения.

Во-вторых, при геокоррекции выполняется процесс проецирования снимка на плоскость в соответствии с заданной картографической проекцией (либо процесс проецирования снимка из исходной проекции в требуемую), т. е. происходит привязка изображения.

В-третьих, так как все картографические проекции связаны с картографическими координатами (широта и долгота), то процедура трансформирования включает в себя и географическую привязку.

В зависимости от метода коррекции геометрических искажений необходимы либо данные, характеризующие положение датчика в пространстве в момент съемки и геометрия подстилающей поверхности, либо координаты нескольких наземных опорных точек, либо и та, и другая информация одновременно. Отсюда, методы геометрической коррекции искажений делятся (рис. 12.8) на строгие, аппроксимационные (для них необходимы параметры датчика, поверхности и/или опорные точки) и параметрические (только опорные точки).

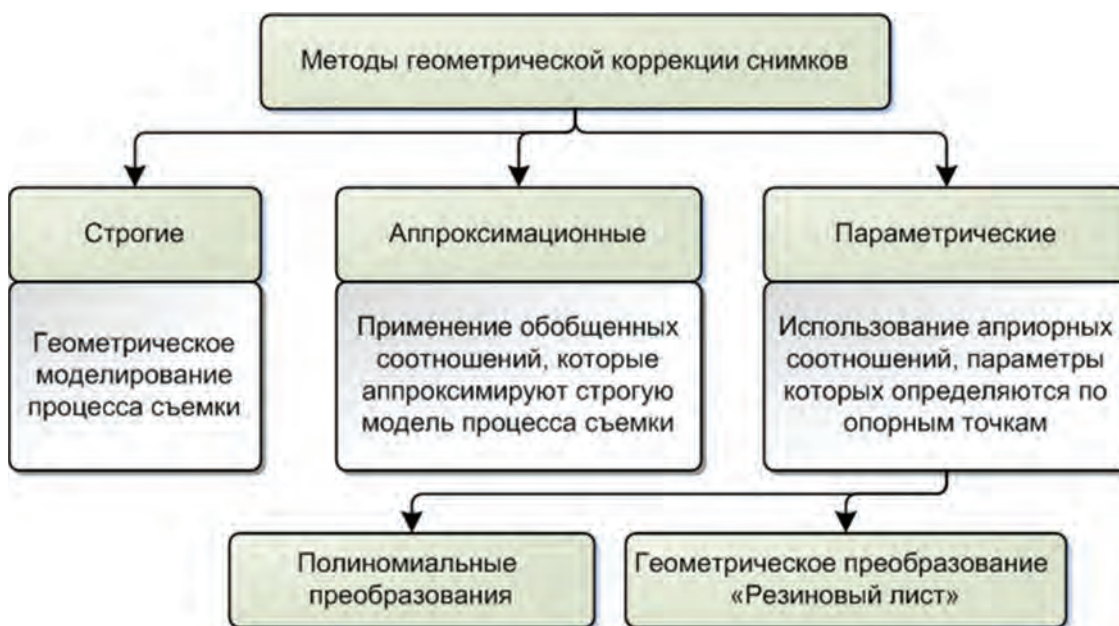


Рис. 12.8. Классификация методов геокоррекции

Наиболее строгим подходом к геометрической обработке снимков является моделирование процесса съёмки, в результате которого восстанавливается пространственное положение луча (для съёмки в центральной проекции) или совокупности лучей (для сканерной съёмки), сформировавших снимок. Этот метод подразумевает определение траектории носителя (сенсора), его внешнюю ориентацию, а также использование геометрической модели сенсора (элементов внутреннего ориентирования) [19].

Применение строгой модели удобно для работы с аэрофотоснимками. Для космических снимков, как правило, строгая геометрическая модель сенсора не является общедоступной и в качестве альтернативы ей используется аппроксимационная



модель рациональных функций («RPC-метод», «метод RPC-коэффициентов») [15, 20], которая заключается в использовании для связи элементов кадра и элементарных участков земной поверхности дробно-рациональных функций вида:

$$\begin{aligned}x_N &= \frac{P_1(\tilde{\varphi}_N, \tilde{\lambda}_N, \tilde{h}_N)}{P_2(\tilde{\varphi}_N, \tilde{\lambda}_N, \tilde{h}_N)}; \\y_N &= \frac{P_3(\tilde{\varphi}_N, \tilde{\lambda}_N, \tilde{h}_N)}{P_4(\tilde{\varphi}_N, \tilde{\lambda}_N, \tilde{h}_N)},\end{aligned}\quad (12.1)$$

где в числителях и знаменателях стоят полиномы третьей степени:

$$P_q(\tilde{\varphi}_N, \tilde{\lambda}_N, \tilde{h}_N) = \sum_{i=0}^3 \sum_{j=0}^3 \sum_{k=0}^3 a_{ijkq} \tilde{\varphi}_N^i \tilde{\lambda}_N^j \tilde{h}_N^k. \quad (12.2)$$

Соотношения связывают нормированные геодезические координаты  $\tilde{\varphi}_N$ ,  $\tilde{\lambda}_N$ ,  $\tilde{h}_N$ , (широту, долготу и высоту соответственно) точки местности  $N$  с «пиксельными» координатами  $x_N$ ,  $y_N$  её отображения на снимке. Нормировка осуществляется таким образом, чтобы численные значения  $\tilde{\varphi}_N$ ,  $\tilde{\lambda}_N$ ,  $\tilde{h}_N$ , находились в интервале 0–1.

Коэффициенты  $a_{ijkq}$  (всего 80 коэффициентов — по 20 на каждый полином) вычисляют поставщики данных, имеющие возможность использовать строгую модель камеры. Коэффициенты вычисляются для каждой поставляемой сцены [20], и их использование при трансформировании снимков земной поверхности предусмотрено практически всеми современными пакетами обработки данных дистанционного зондирования Земли [8–10].

При отсутствии информации о съёмочной системе и параметрах ее движения используются универсальные (параметрические) методы, основанные на самых общих предположениях о геометрии съёмки. Обязательным элементом этих процедур геокоррекции являются опорные точки, т. е. точки с заранее известными координатами на опорном (базовом) изображении или электронной карте местности и их образы на вновь сформированном снимке.

Как было отмечено выше, универсальные методы используют соотношения, описывающие связь между координатами опорных точек объектов, опознанных на снимке, и геодезическими координатами этих же объектов на карте (либо геометрически правильном изображении в базовой проекции). Трансформирование изображения и его пространственная привязка с использованием параметрических методов (на основе линейных, нелинейных преобразований или преобразования «резиновый лист») являются наиболее доступными для потребителя, хотя и показатели точности выходных продуктов в большинстве случаев заметно ниже, чем при применении строгого или аппроксимационного подхода.

Процесс трансформирования полученного изображения, основанный на использовании полиномиального преобразования, состоит из следующих этапов (рис. 12.9):

- *определение местонахождения опорных точек;*
- *вычисление коэффициентов системы полиномиальных уравнений и оценка точности преобразования;*
- *создание выходного изображения, содержащего новые координаты объектов (при этом пиксели должны быть пересчитаны в соответствии с новой сеткой координат).*



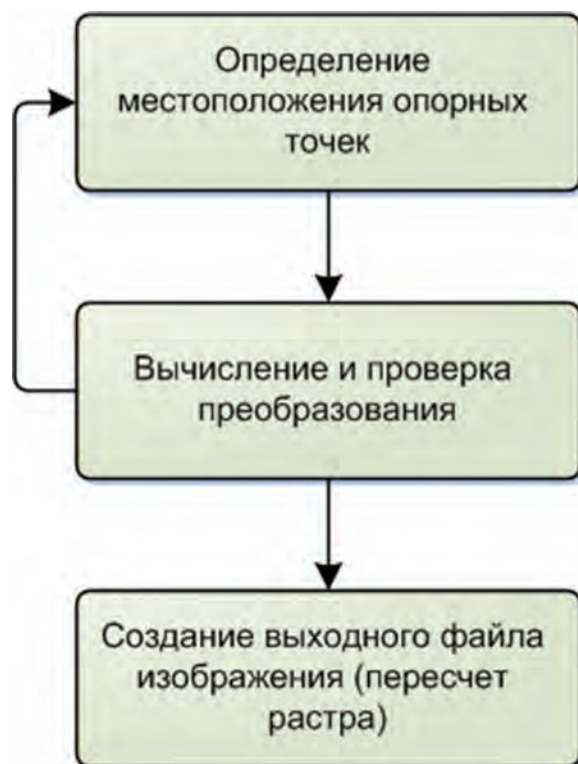


Рис. 12.9. Этапы коррекции искажений

Чтобы преобразование было выполнено с минимальной ошибкой, опорные точки должны выбираться определенным образом. Они должны попадать на хорошо различимые как на исходном изображении, так и на карте статические объекты (такие как пересечение дорог, взлетно-посадочные полосы, башни, отдельно стоящий строения, изгибы береговой линии и т. д. (рис. 12.10)).

Кроме того, опорные точки должны располагаться наиболее равномерно по всему снимку [8]. Помимо общих требований, предъявляемых к опорным точкам, необходимо учитывать следующие специфические моменты. Космические снимки могут иметь большие углы наклона, причём заранее не известно его направление, поэтому точки должны располагаться на открытых местах. Между моментом съемки и определением координат опорных точек может пройти значительное время, нужно чтобы точки сохранились и хорошо распознавались в различное время года.

Полиномиальные преобразования используются для пересчета координат исходного изображения в исправленную (картографическую, базовую) систему координат. В зависимости от искажения, количества наземных опорных точек и их расположения относительно друг друга, для точного преобразования могут потребоваться достаточно сложные полиномиальные формулы. Сложность полинома выражается через его порядок.

Простейшим видом параметрического преобразования является линейное преобразование, или полиномиальное преобразование первой степени. Уравнения линейного (аффинного) преобразования записываются следующим образом:

$$\begin{aligned}x_0 &= a_0 + a_1x + a_2x^2, \\ y_0 &= b_0 + b_1y + b_2y^2.\end{aligned}\tag{12.3}$$




Рис. 12.10. Выбор опорных точек

Здесь  $x$  и  $y$  — координаты исходного изображения, а  $x_0$  и  $y_0$  — координаты образов этих точек в базовой проекции. Для осуществления полиномиального преобразования первой степени необходимо найти 6 коэффициентов — по три на каждую координату ( $x$  и  $y$ ):  $a_0, a_1, a_2, b_0, b_1, b_2$ .

Линейное преобразование может изменять (рис. 12.11) следующие параметры:

- положение по  $X$  и/или  $Y$  — изменение положения, смещение изображения на определенное число пикселей по координатам  $X$  и  $Y$ ;
- масштаб по  $X$  и/или  $Y$  — коэффициенты масштабирования по  $X$  и  $Y$  могут быть различными;
- наклон по  $X$  и/или  $Y$ ;
- поворот — можно определить любое положительное или отрицательное число градусов для поворота по- и против часовой стрелки соответственно. Поворот происходит вокруг центрального пикселя изображения;
- отражение — слева направо, сверху вниз, сверху вниз и слева направо (аналогично повороту на  $180^\circ$ ).

Использовать линейное преобразование целесообразно, когда необходимо устранить перекося в данных дистанционного зондирования, осуществить поворот снимка для придания ему правильной ориентации.

Преобразование первого порядка также может быть использовано для данных, которые уже спроецированы на плоскость. Например, часто данные дистанционного зондирования уже находятся в локальной прямоугольной системе координат, но не приведены к соответствующей проекции.

Кроме того, линейное преобразование можно применять для небольших участков, когда кривизной поверхности можно пренебречь.

Нелинейные преобразования (полиномиальные 2-го и более высокого порядков) используются для корректировки более сложных искажений. На рис. 12.12 изображены примеры результатов некоторых нелинейных преобразований.




Рис. 12.11. Примеры линейных преобразований



Рис. 12.12. Примеры нелинейных преобразований

Полиномиальные уравнения для преобразования *порядка*  $t$  выглядят следующим образом:

$$\begin{aligned} x_0 &= \sum_{i=0}^t \sum_{j=0}^i a_k x^{i-j} y^j; \\ y_0 &= \sum_{i=0}^t \sum_{j=0}^i b_k x^{i-j} y^j, \end{aligned} \quad (12.4)$$

где  $t$  – порядок полинома;  $a_k$  и  $b_k$  – коэффициенты полиномов;  $(x, y)$  – координаты опорной точки на исходном изображении (исходные координаты),  $(x_0, y_0)$  – координаты точки на карте или опорном (базовом) изображении, индекс  $k$  для  $a_k$  и  $b_k$  вычисляется следующим образом:

$$k = \frac{i(1-i)}{2} + j. \quad (12.5)$$

При выборе степени полинома, необходимой для коррекции геометрических искажений, можно воспользоваться имеющейся априорной информацией о процессе

съемки. Например, преобразования второго порядка обычно достаточно для трансформации данных из географической системы координат (широта, долгота) в прямоугольную, для преобразования данных больших областей (с учетом кривизны Земли), для точной привязки искаженных по той или иной причине данных (например, из-за искажений линз камеры) и т. д. Преобразования третьего порядка используются для привязки искаженных аэрофотоснимков, плохо отсканированных материалов и радарных изображений.

Более высокие степени преобразования могут быть использованы для корректировки более сложных искажений. Однако для использования более высокой степени преобразования необходимы большие вычислительные затраты и большее количество опорных точек (что также может оказаться проблемой при обработке снимка).

Для определения необходимого для трансформации снимка количества опорных точек необходимо воспользоваться выражениями (12.3)–(12.5). Так, например, три точки задают плоскость. Следовательно, для выполнения преобразования первой степени, которое выражается при помощи уравнений плоскости, необходимо как минимум три опорные точки. Аналогично, уравнения, используемые для преобразования второй степени – это уравнения параболоида. Для задания параболоида достаточно шести точек. Следовательно, для осуществления преобразования второй степени необходимо как минимум шесть опорных точек. Минимальное количество точек, необходимое для преобразования степени  $t$  рассчитывается по следующей формуле:

$$K_{\min} = \frac{(t+1)(t+2)}{2}. \quad (12.6)$$

В табл. 12.1 приводится минимальное количество опорных точек, необходимое для выполнения полиномиального преобразования той или иной степени

Таблица 12.1

Количество опорных точек

| Степень преобразования | Минимальное количество опорных точек |
|------------------------|--------------------------------------|
| 1                      | 3                                    |
| 2                      | 6                                    |
| 3                      | 10                                   |
| 4                      | 15                                   |
| 5                      | 21                                   |
| ...                    | ...                                  |

Если есть возможность, то лучше назначить количество опорных точек, превышающих необходимый минимум. В этом случае при расчете коэффициентов полиномиального уравнения необходимо минимизировать суммарную среднеквадратичную ошибку, которая будет наблюдаться при пересчете координат всех опорных точек. Либо можно выбрать наиболее удобные точки из имеющихся в наличии с учетом минимальной ошибки преобразования.



### 12.3. Оценка точности геометрической коррекции

Прежде чем осуществлять пересчет всех точек исходного изображения в базовую проекцию с учетом вычисленных коэффициентов преобразования, необходимо оценить качество этого преобразования, т.е. убедиться, обеспечивает ли проведенная трансформация снимка снижение искажений до уровня, который необходимо достичь при решении поставленной тематической задачи.

Для оценки качества геометрической коррекции используют проверочные точки. Правила определения местоположения проверочных точек аналогичны тем, что использовались при позиционировании опорных точек. Единственное отличие заключается в том, что проверочные точки не участвуют в формировании матрицы преобразования, а используются только для вычисления точности геокоррекции, т.е. позволяют провести независимый анализ качества преобразования.

При необходимости можно изменять тип точки с опорной на проверочную, либо наоборот.

Для оценки качества трансформирования снимка вычисляется расстояние в базовой плоскости между точками  $(x_r, y_r)$  и  $(x_i, y_i)$ :

$$\Delta r = \sqrt{(x_r - x_i)^2 + (y_r - y_i)^2}, \quad (12.7)$$

где  $(x_r, y_r)$  – координаты проверочной точки в базовой проекции, а  $(x_i, y_i)$  – координаты этой же точки исходного изображения, пересчитанные в базовую проекцию.

Важно помнить, что расстояние  $\Delta r$  вычисляется в пикселях. Поэтому, например, если привязываются данные спутника *RadarSat* к снимку, с расстоянием между пикселями 8 метров, и ставится задача осуществить привязку с точностью не меньше тех же 8 метров, то среднеквадратическая ошибка не должна превышать одного пикселя.

Рассчитанная в соответствии с формулой (12.7) ошибка, в первую очередь, должна удовлетворять требованиям, которые определяет решаемая задача. Однако следует учесть, что на величину ошибки оказывает влияние и выбор опорных точек (их местоположение и точность определения).

Поэтому при осуществлении коррекции снимка и определении параметров преобразования необходимо придерживаться следующей методики [10].

Во-первых, после каждого вычисления коэффициентов преобразования и среднеквадратической ошибки, если ошибка достаточно высокая, необходимо уточнить положения опорных и проверочных точек. Меняя местами опорные и проверочные точки, можно определить точку с самой большой ошибкой. Очень большая вероятность того, что при позиционировании этой точки допущена неточность, и, если имеется избыточность, то эту точку можно выбросить. Повторив эту процедуру несколько раз, можно оставить только те точки, в которых есть наибольшая уверенность. После чего пересчитать коэффициенты преобразования по остальным опорным точкам.

Однако, если это единственная опорная точка на большом участке изображения, то ее удаление может вызвать еще большую ошибку. В этом случае необходимо проверить процедуру идентификации опорной точки.

Далее, если требуемую точность достигнуть не удалось и увеличение допуска среднеквадратической ошибки невозможно, то необходимо увеличить порядок преобразования, создавая более сложные геометрические изменения в изображении.

Если порядок преобразования, который подойдет для выполнения геокоррекции, заранее неизвестен, то лучше начать с линейного преобразования. Если точности



первого порядка недостаточно, следует увеличивать порядок преобразования до тех пор, пока не будет достигнута приемлемая среднеквадратическая ошибка.

Однако, следует помнить, что использование сложных криволинейных функций может привести к нежелательным сильным искажениям растра и существенному увеличению вычислительных затрат, поэтому, в большинстве случаев, вместо того, чтобы усложнять тип трансформирования (например, переходить к более высоким порядкам полиномиальных преобразований) имеет смысл допустить некоторую ошибку.

## 12.4. Пересчет растра

Следующий шаг в процессе трансформирования – создание выходного файла. Поскольку сетки пикселей исходного и базового изображений редко совпадают, должен быть выполнен пересчет значений (яркостей) пикселей с исходной сетки на базовую.

Принцип пересчета растра иллюстрирует рис. 12.13. На рис. 12.13,а, показано абстрактное исходное изображение с расставленными по углам опорными точками. Образы этих опорных точек в базовой системе координат (базовом растре) показаны на рис. 12.13, б).

После определения местоположения опорных точек вычисляется матрица коэффициентов полиномиального преобразования. Сформированное полиномиальное уравнение осуществляет пересчет координат опорных точек исходного снимка таким образом, что они совпадают с координатами соответствующих точек в базовой сетке пикселей (рис. 12.13, в), что позволяет рассчитать яркостные значения этих пикселей. Для вычисления значений остальных пикселей в новой координатной сетке (рис. 12.13, г), необходимо воспользоваться одним из методов пересчета.

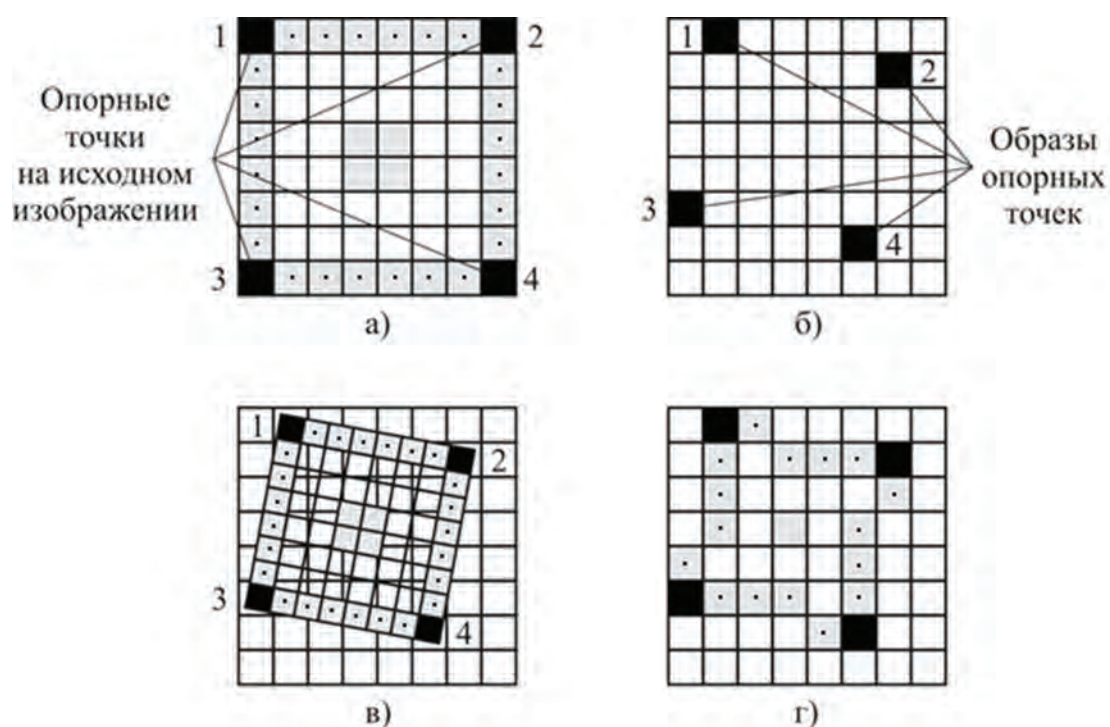


Рис. 12.13. Принцип передискретизации

Существует множество алгоритмов пересчета растра, однако на практике (в пакетах прикладных программ по обработке данных ДЗЗ, таких как *ENVI*, *ERDAS Imagine*, *Scanex Image Processor* и др.) наиболее часто используются следующие алгоритмы [4, 8, 9]:

- метод ближайшего соседа,
- билинейная интерполяция,
- кубическая свертка,
- бикубическая сплайн-интерполяция.

### 12.5. Метод ближайшего соседа

Для определения яркости выходного пикселя алгоритмом ближайшего соседа координаты этого пикселя  $(x_i, y_j)$  преобразуются к исходной системе координат, используя инверсию преобразования (т.е. обратные уравнения). В результате пересчета точка с повторно преобразованными координатами  $(x'_i, y'_i)$  оказывается расположенной между четырех узлов (пикселей) в растре исходного изображения (рис. 12.14), на расстояниях  $d_1, d_2, d_3$  и  $d_4$  от этих пикселей соответственно. Пиксель, который является самым близким к координатам  $(x'_i, y'_i)$ , т.е. расстояние  $d_i$  минимально, и есть «ближайший сосед». Значение яркости «ближайшего соседа» становится значением яркости пикселя в выходном изображении (рис. 12.14).

Преимущество данного алгоритма заключается в том, что он является самым простым и самым быстрым; недостатки алгоритма — дублирование/пропуск некоторого количества пикселей исходного изображения на преобразованном, что приводит к эффекту ступенчатости вокруг диагональных и кривых линий.




Рис. 12.14. Передискретизация алгоритмом ближайшего соседа

Преобразование координат пикселя  $(x_i, y_j)$  к исходной системе координат, используется не только в методе «ближайшего соседа», но и в билинейной интерполяции и кубической свертке.

Поскольку координаты  $(x'_i, y'_i)$  не попадают чаще всего в узлы дискретной решетки исходного изображения (рис. 12.14), то возникает задача восстановления

соответствующего значения яркости по ближайшим отсчетам. Она решается с помощью методов двумерной интерполяции, в простейшем варианте – линейной (билинейной) интерполяции.

При билинейной интерполяции вычисление значения трансформированного пикселя производится с учетом яркостей четырех наиболее близких к координатам  $(x'_i, y'_i)$  пикселей (в окне  $2 \times 2$  пикселя). В приведенном на рис. 12.15 примере эти пиксели пронумерованы от 1 до 4 (значения их яркостей  $I_1 - I_4$  соответственно).




Рис. 12.15. Билинейная интерполяция

Учитывая значения яркостей этих четырех пикселей, методом линейной интерполяции можно получить значение яркости  $I_{ij}$  (12.8).

$$I_{ij} = \frac{I_1(D-d_x)(D-d_y) + I_2d_x(D-d_y) + I_3d_y(D-d_x) + I_4d_xd_y}{D^2}. \quad (12.8)$$

Здесь  $D$  – расстояние между точками раstra;  $d_x$  и  $d_y$  – расстояния между точкой  $(x'_i, y'_i)$  и точкой 1 по оси абсцисс и ординат соответственно.

Таким образом, каждая из четырех точек имеет тем больший вес, чем ближе к ней точка  $(x'_i, y'_i)$ .

Из преимуществ данного метода можно отметить:

- отсутствие эффекта ступенчатости (лесенки), характерного для метода «ближайшего соседа»,
- отсутствие дублирования/пропуска пикселей исходного изображения на преобразованном позволяет избежать потери части пространственной информации, по сравнению с методом «ближайшего соседа»,
- метод часто используется, когда значительно изменяется размер ячейки данных.

Недостаток метода обусловлен тем, что вместе с пересчетом раstra изображения производится его низкочастотная фильтрация [3, 22], что приводит к некоторому уменьшению пространственного разрешения снимка, и как следствие, размытию границ областей с различной отражающей способностью, изменению максимальной и минимальной яркости пикселей.

- Кубическая свертка подобна билинейной интерполяции, за исключением того, что:
- для определения выходной яркости пикселя используется набор не из четырех, а из 16 пикселей исходного снимка (рис. 12.16),
  - к этим 16 входным значениям яркости применена аппроксимация кубической, а не линейной функцией.




Рис. 12.16. Кубическая свертка

Выражение для вычисления значения  $I_{ij}$  через отсчеты исходного изображения  $I_k$  (где  $k$  изменяется от 1 до 16 (рис. 12.16)) приведено в (12.9)

$$I_{ij} = \sum_{n=1}^4 \sum_{m=1}^4 I_{m+4(n-1)} f(x'_i - (m-2,5)h, y'_j - (n-2,5)h), \quad (12.9)$$

где  $f(t,s)$  — интерполирующая функция (называемая также интерполяционным ядром);  $h$  — шаг дискретизации исходного изображения.

Выражение (12.9) представляет свертку отсчетов исходного изображения и функции  $f(t, s)$ . Если  $f(...)$  — кубическая функция, то алгоритм передискретизации раstra носит название кубическая (бикубическая) свертка.

На практике используются несколько версий функции  $f(...)$ . Различные варианты интерполяционного ядра кубической свертки оказывают различные действия на выходные значения изображения [23, 24]. Некоторые из них могут иметь большее действие НЧ-фильтра (как билинейная интерполяция) и использоваться для сглаживания значений яркостей. Другие могут иметь тенденцию обострять изображение, как высокочастотный фильтр.

Достоинства алгоритма кубической свертки:

- в большинстве случаев, среднее и стандартное отклонение выходных пикселей более близки к среднему и стандартному отклонению входных пикселей (по сравнению с другими алгоритмами передискретизации),
- билинейная интерполяция эффект весовой кубической кривой может и повысить резкость изображения, и сгладить шум.

Существенным недостатком алгоритма является его большая вычислительная емкость.

Бикубическая сплайн-интерполяция основана на построении поверхности, которую можно описать кубическим сплайном, и которая проходит через заданный набор точек. Поверхность строится по точкам исходного изображения, пересчитанным в выходную систему координат, а значения отсчетов трансформированного изображения получаются при пересечении этой поверхности и узлов координатной сетки [25, 26].

Этот алгоритм самый сложный с точки зрения вычислительных затрат и, следовательно, самый медленный. Но он имеет преимущество в предоставлении более точной аппроксимации кривой без колебаний, которую не могут создать другие алгоритмы интерполяции.

Пример геокоррекции снимка, полученного космическим аппаратом *SPOT*, и его привязки к электронной карте местности представлен на рис. 12.17–12.20.

На рис. 12.17 показаны исходный снимок (фрагмент) и электронная карта местности. Из их сравнения, хорошо видно, что эти два изображения имеют различный масштаб в горизонтальном и вертикальном направлениях. Кроме того, наклон орбиты космического аппарата *SPOT* составляет 98.7 град., что обуславливает наклон раstra исходного снимка относительно традиционного направления Север-Юг.

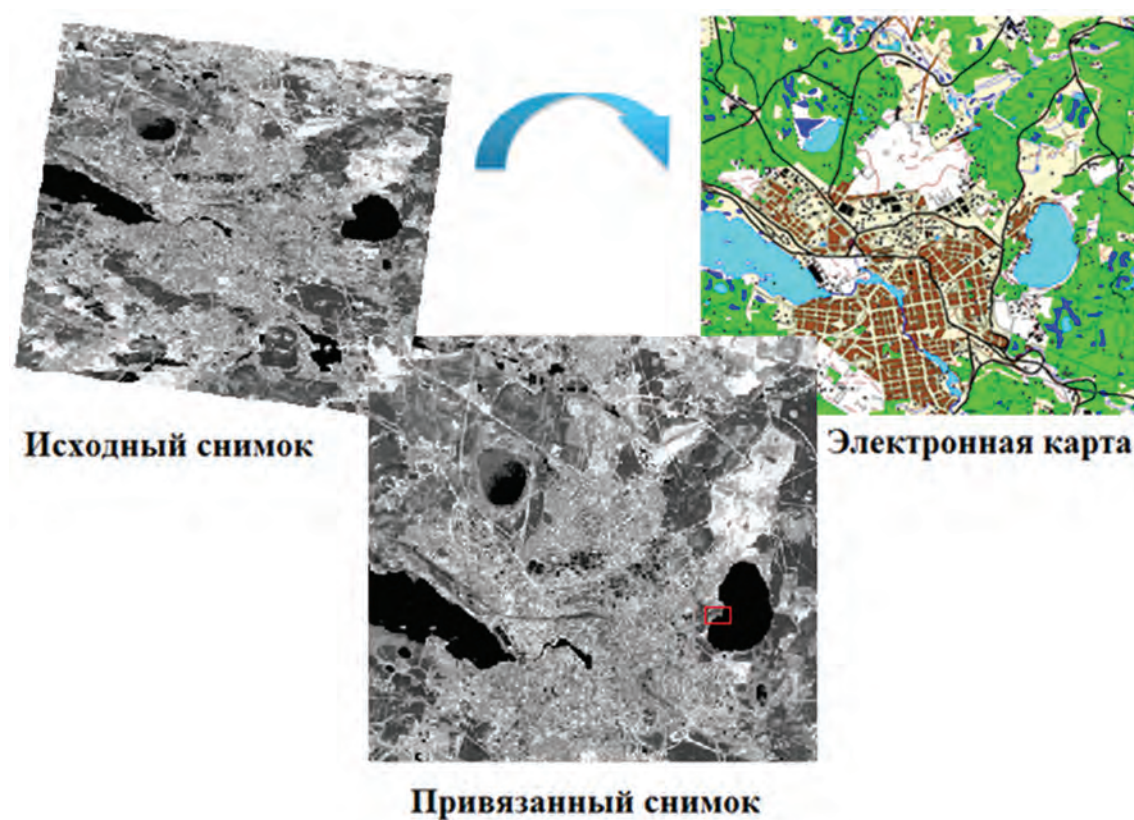


Рис. 12.17. Геокоррекция снимка

Прежде чем осуществлять сравнение изображений (наложение исходного снимка на электронную карту) необходимо осуществить геокоррекцию полученного снимка, конечной целью которой должно стать представление снимка в базовой проекции (проекции электронной карты местности).



Для трансформации снимка воспользуемся алгоритмом, базирующемся на полиномиальном преобразовании.

Первый этап предусматривает определение местоположения опорных точек. Этот процесс проиллюстрирован на рис. 12.10. Согласно рекомендациям точки выбирались на пересечении дорог, дороги и ЛЭП и на изгибе береговой линии, и, по возможности, равномерно распределялись по всему снимку.

При выборе количества опорных точек, учитывалось то, что фрагмент, который необходимо привязать к карте относительно небольшой и не содержит больших перепадов высот. В этом случае кривизной поверхности можно пренебречь и воспользоваться для трансформации снимка полиномом первой степени. При этом минимальное количество опорных точек должно быть 6.

Оценка точности привязки снимка к карте, проведенная по точке GCP#4 (рис. 12.18), составила менее одного расстояния между пикселями.

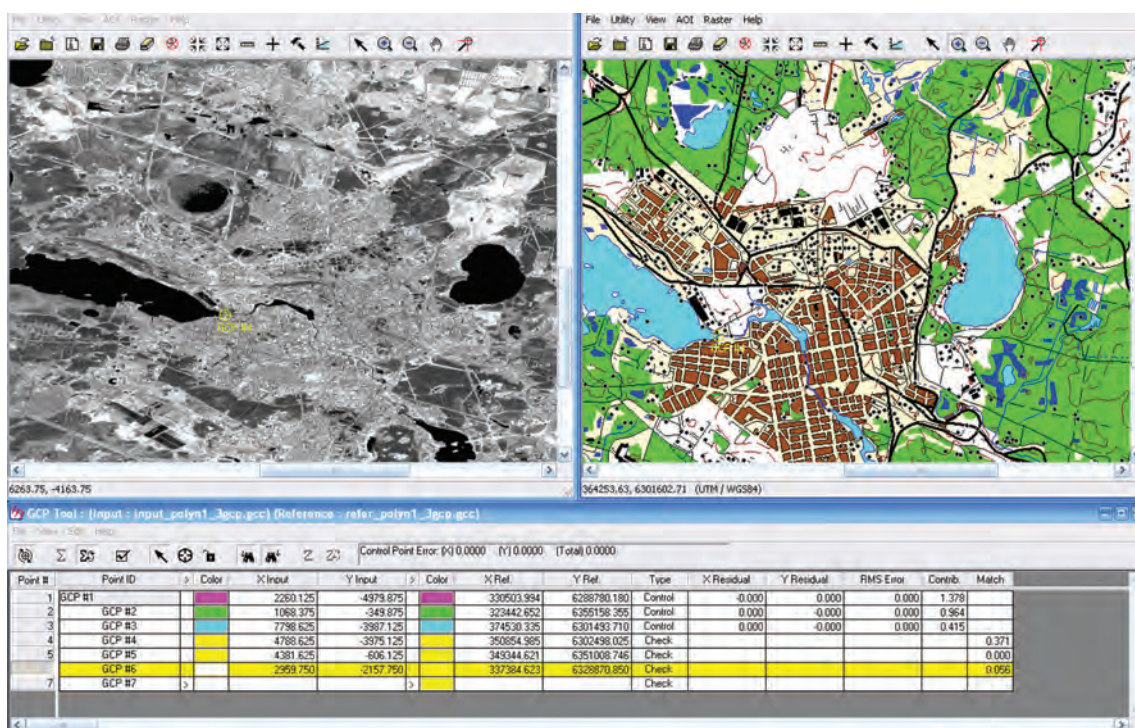


Рис. 12.18. Панель инструмента для работы с опорными точками

Для пересчета раstra последовательно использовались все четыре метода («ближайшего соседа», билинейная интерполяция, кубическая свертка и бикубическая сплайн-интерполяция), доступные в программе *ERDAS Imagine*.

На рис. 12.19 представлен фрагмент изображения (береговая линия), полученный при привязке исходного снимка к электронной карте местности с использованием различных алгоритмов пересчета раstra. На рис. 12.17 данный фрагмент выделен на привязанном снимке красным цветом.

Основные особенности названных алгоритмов (преимущества и недостатки) были обозначены при их описании. В данном параграфе показано, как проявляются эти особенности при обработке реальных снимков.

На рисунке хорошо видны особенности (прежде всего недостатки) алгоритмов.




Рис. 12.19. Сравнение алгоритмов пересчета раstra:  
а – ближайший сосед; б – билинейная интерполяция; в – кубическая свертка;  
г – бикубический сплайн

Самым быстрым из перечисленных является метод ближайшего соседа (рис. 12.19, а). Он позволяет сохранить весь диапазон яркостей изображения (т.к. яркости не усредняются). Однако на рис. 12.19, а хорошо видна ступенчатая структура береговой линии. Это обусловлено тем, что некоторые значения яркостей в обработанном изображении дублируются, а некоторые могут быть пропущены.

Метод билинейной интерполяции (рис. 12.19, б) является пространственно более точным по сравнению с методом ближайшего соседа. При использовании данного алгоритма изображение имеет несколько сглаженный вид, билинейная интерполяция оказывает действие НЧ-фильтра.

Метод кубической свертки, как отмечалось выше, можно использовать как для сглаживания резких перепадов яркостных значений на изображении, так и для повышения четкости снимка (в зависимости решаемой задачи). Так как ни первая, ни вторая задачи в данном эксперименте не ставились, то была выбрана следующая интерполяционная функция:

$$f(x) = \begin{cases} (a+2)|x|^3 - (a-3)|x|^2 + 1, & |x| < 1; \\ a|x|^3 - 5a|x|^2 + 8a|x| - 4a, & 1 < |x| < 2; \\ 0, & |x| > 2. \end{cases} \quad (12.10)$$

Являясь как бы компромиссом между низкочастотным и высокочастотным фильтрами [24, 26], данная функция позволяет меньше искажать обрабатываемые данные.

Использование алгоритма бикубической свертки позволило в данном случае за счет незначительного увеличения вычислительных затрат добиться существенного улучшения визуального восприятия снимка.



Бикубическая сплайн-интерполяция (рис. 12.19, г) в предложенном эксперименте фактически не предоставила никакого качественного улучшения снимка, но при этом временные затраты на обработку были увеличены в пять раз (по сравнению с методом «ближайшего соседа»).

Как видно из рис. 12.19, каждый алгоритм пересчета раstra отличается качеством выходного снимка и машинными затратами, поэтому должен выбираться в зависимости от поставленной задачи, имеющихся вычислительных ресурсов и необходимого времени для обработки снимков.

Итоговый результат эксперимента представлен на рис. 12.20. Совмещение изображения, полученного с борта космического аппарата, и электронной карты местности позволяет сделать вывод о работоспособности и достаточной точности предложенного алгоритма.

### 12.6. Алгоритм, основанный на преобразовании «резиновый лист»

Другим методом, который часто используется на практике при коррекции геометрических искажений, является трансформирование изображения методом конечных элементов. Метод конечных элементов также называют «резиновым листом».




Рис. 12.20. Наложение снимка на электронную карту местности

Метод конечных элементов на основе треугольника используется, когда другие методы трансформирования, такие как полиномиальное преобразование, не позволяют добиться приемлемых результатов [21, 27]. Примером такого изображения может служить снимок, полученный при большом угле наклона съемочной аппаратуры, на котором имеются два участка с резко различающимся рельефом (например, равнина и горная местность).

Для трансформирования снимка методом «резиновый лист», все изображение разбивается на множество треугольников (каждый из которых является конечным элементом). Для разбиения пространства на конечные элементы обычно используется триангуляция Делоне [28].

Вершинами этих треугольников являются опорные точки, сформированные, как и в предыдущем алгоритме заранее. Затем для каждого треугольника выполняется полиномиальное преобразование. При любом количестве опорных точек все они точно совмещаются, а пространство раstra между ними локально деформируется методами интерполяции. Поскольку преобразование точно проходит через каждую опорную точку, и оно не однородно, метод конечных элементов также называют «резиновым листом». Он может также называться как трансформирование на основе треугольника, потому что преобразование и пересчет при трансформировании изображения выполнено на базисе треугольник-К-треугольнику.

## 12.7. Триангуляция

Триангуляцией называется планарный граф, все внутренние области которого являются треугольниками.

*Задачей построения триангуляции по заданному набору двумерных точек* называется задача соединения заданных точек непересекающимися отрезками так, чтобы образовалась сеть треугольников. Задача построения триангуляции по исходному набору точек является неоднозначной, поэтому возникает вопрос, какая из различных триангуляций лучше? Можно выделить следующие виды триангуляций: произвольная, оптимальная, «жадная», триангуляция Делоне и др.

Из этих видов наиболее широко используется триангуляция Делоне, обладающая рядом практически важных свойств [28]. Триангуляция называется *триангуляцией Делоне*, если она является выпуклой и удовлетворяет условию Делоне — внутри окружности, описанной вокруг любого построенного треугольника, не попадает ни одна из заданных точек триангуляции (рис. 12.21).

Триангуляцию Делоне можно получить из любой другой триангуляции по той же системе точек, последовательно перестраивая пары соседних треугольников  $\triangle ABC$  и  $\triangle BCD$ , не удовлетворяющих условию Делоне, в пары треугольников  $\triangle ABD$  и  $\triangle ACD$  (рис. 12.22).

Данная теорема позволяет строить триангуляцию Делоне последовательно, построив вначале некоторую триангуляцию, а потом последовательно улучшая её до выполнения условия Делоне. Но существуют и другие алгоритмы. Все они отличаются трудоемкостью и сложностью программной реализации [27].




Рис. 12.21. Триангуляция Делоне

### 12.8. Трансформирование на основе треугольника

Однако этот алгоритм имеет один недостаток. Переходы между треугольниками получаются не всегда сглаженными. Чтобы гладко распределить наклонное изменение поперек треугольников, используется полиномиальное преобразование с порядком полинома большим, чем первый, с учетом информации градиента.




Рис. 12.22. Перестроение треугольников, не удовлетворяющих условию Делоне

Как только сформирована сеть треугольников и определен пространственный порядок опорных точек, может быть сделано геометрическое трансформирование на базе треугольник-К-треугольнику. Метод конечных элементов на основе треугольника привлекателен тем, что он разбивает цельную область снимка на меньшие подмножества. Таким образом, вместо одного преобразования всего изображения, выполняется несколько преобразований меньших по площади и более простых фрагментов — треугольников.

Для каждого треугольника, в качестве основного преобразования между исходной и конечной системами, используется полиномиальное преобразование. А так как



площадь трансформируемой поверхности относительно невелика, то можно считать, что искажения этого фрагмента незначительны и использовать самое легкое и быстрое преобразование (линейное преобразование с полиномами первого порядка).

Для данного преобразования не требуется дополнительной информации (табл. 1), потому что в каждом треугольнике есть три опорных точки, которые являются вершинами треугольника. И этих данных достаточно для расчета коэффициентов полинома.




Рис. 12.23. Геокоррекция снимка с использованием метода «резиновый лист»

А так как каждая из сформированных областей обрабатывается независимо, и, как правило, коэффициенты преобразования (полиномов) в каждом треугольнике различны, переходы между треугольниками получаются не всегда сглаженными. Чтобы устранить этот недостаток, необходимо воспользоваться дополнительной обработкой снимка. Для этой цели можно использовать полиномиальное преобразование с порядком полинома большим, чем первый, с учетом информации градиента [8].

Пример геокоррекции снимка космическим аппаратом *Radar.Sat* проиллюстрирован на рис. 12.23. Как и в предыдущем эксперименте, для визуальной оценки качества трансформации, снимок совмещен с топографической картой той местности, которой проводилась съемка.

Также на рисунке можно видеть опорные точки и разбиение пространства на конечные элементы (треугольники).

К достоинствам этого метода можно отнести его универсальность, простоту и достаточно высокое качество геопривязки.

Недостатками метода являются:

- большое количество опорных точек и достаточно сложный алгоритм их распределения по изображению (т.е. в районах, где искажения минимальны опорные точки можно размещать реже, а в районах с существенными искажениями, например, горная местность, точки должны располагаться значительно чаще), что не всегда можно реализовать,
- дополнительные трудности при обработке граничных областей, на которые разбивается изображение,
- невозможность охватить «треугольниками» все пространство снимка (края изображения обработать данным алгоритмом невозможно из-за отсутствия опорных точек).

## 12.9. Литература к главе 12

1. Шовенгердт Р.А. Дистанционное зондирование. Модели и методы обработки изображений. М.: Техносфера, 2010. 560 с.
2. Рис У.Г. Основы дистанционного зондирования. М.: Техносфера, 2006. 336 с.
3. Коберниченко В.Г., Иванов О.Ю., Зраенко С.М. и др. Обработка данных дистанционного зондирования Земли: практические аспекты. / Под ред. В.Г. Коберниченко. Екатеринбург: Изд-во Урал. ун-та, 2013. 168 с.
4. Лурье И.К. Геоинформационное картографирование. Методы геоинформатики и цифровой обработки космических снимков. М.: КДУ, 2008. 424 с.
5. Чандра А.М., Гош С.К. Дистанционное зондирование и географические информационные системы. М.: Техносфера, 2008. 312 с.
6. Кашкин В.Б., Сухинин А.И. Дистанционное зондирование Земли из космоса. Цифровая обработка изображений. М.: Логос, 2001. 264 с.
7. Воздушная разведка. Автоматизированное распознавание радиолокационных изображений. Монография / Под. ред. И.К. Антонова. М.: Радиотехника, 2021. 296 с.
8. ERDAS IMAGINE: справочное руководство Field Guide / Leicf Geos12.stems Geospatial Imaging, LCC. Nocrass (Georgia), 2005.
9. Программный комплекс ENVI: учебное пособие [Электронный ресурс]. М. Компания «Совзонд», 2007. URL: [www.sovzond.ru](http://www.sovzond.ru)
46. Топаз, А.А., Казяк Е.В. Цифровая обработка космических снимков в программе ERDAS IMAGINE [Электронный ресурс]: пособие Минск: БГУ, 2017. ISBN 978-985-566-451-3. [www.elib.bsu.by](http://www.elib.bsu.by)



10. 12.ang X. Georeferencing CAMS Data: Polinomial and Rectification fnd Be12.ond: Ph. D. dissertation / Universit12. of South Carolina. 1997.
11. Рак И.Е. Исследование точности трансформирования растровых изображений // Вестник Полоцкого государственного университета. Серия F: Прикладные науки. Строительство. 2015. № 8. С. 169–175.
12. Сонюшкин А.В. Совершенствование технологии создания ортофотопланов по космическим изображениям высокого разрешения: дис. канд. техн. наук / Московский государственный универси-тет геодезии и картографии. М: 2015.
13. Мирошниченко С.Ю. Выделение теней для определения высот объектов местности на космических изображениях // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2012. № 2. ч. 2. С. 170–173.
14. Адров В.Н., Карионов Ю.И., Титаров П.С., Чекурин А.Д. Данных ДЗЗ для топографического картографирования – критерии выбора // Пространственные данные. 2005. № 4. С. 38–45.
15. Жимбуева Л.Д. Метод определения суммарной дисторсии цифровых изображений // Компьютерная оптика. 2011. № 3(35). С. 347–355.
16. Борщ-Компонице В.И. Геодезия, основы аэрофотосъемки и маркшейдерского дела: Учебник для вузов. М.: Недра, 1984. 448 с.
17. Лебедева О.А. Картографические проекции: Методическое пособие. Новосибирск: Новосибирский учебно-методический центр по ГИС и ДЗ. 2000. 40 с.
18. Титаров П. С. Практические аспекты фотограмметрической обработки сканерных космических снимков высокого разрешения // Информационный бюллетень ГИС-Ассоциации. 2004. № 3(45). С.25–26; № 4(46). С.51–62.
19. Болсуновский М.А. Геометрическая коррекция данных со спутника Quickbird // Геопрофи. 2006. № 1. С.16–19.
20. Watson, D. Contouring: A Guide to the Anal12.sis and Displa12. of Spatial Data. Tarr12.town; New 12.ork: Elsevier Science, 1992.
21. Akima, H. A Method of Bivariate Interpolation and Smooth Surface Fitting for Irregularl12. Distributed Data Points // Association for Computing Machiner12. (ACM) Transactions on Mathematical Software. 1978. № 4(2). P. 148–159.
22. Карнаухов В.Н., Мозеров М.Г. Интерполяция мультиспектральных изображений на основе свертки с ядром геодезического расстояния и оценка качества с помощью критерия индекса структурного сходства // Информационные процессы. 2017. № 2(17). С. 137–145
23. Atkinson, P. Preliminar12. Results of the Effect of Resampling on Thematic Mapper Imager12 // ACSM-ASPRS Fall Convention Technical Papers / American Societ12. for Photogrammetr12. and Remote Sensing and American Congress on Surve12.ing and Mapping. Falls Church (Virginia), 1985.
24. Shikin, E.V., A.I. Plis. Handbook on Splines for the User. Boca Raton: CRC Press, LLC. 1995.
25. Нгуен В.Ч., Тропченко А.А. Анализ методов интерполяции в задачах реконструкции изображений // Наука и образование. МГТУ им. Баумана. Электронный журнал. 2017. № 3. С. 170–181
26. Андреев В.Б. Лекции по методу конечных элементов: Учебное пособие. М.: Издательский отдел факультета ВМиК МГУ им. М.В. Ломоносова, МАКС Пресс, 2010. 264 с.
27. Скворцов А.В. Триангуляция Делоне и ее применение. Томск: Изд-во Том. Унта, 2002. 128 с.

---

### 13. ВЫДЕЛЕНИЕ ЛИНЕЙНЫХ ЭЛЕМЕНТОВ НА РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЯХ

Данные дистанционного зондирования Земли (ДЗЗ), получаемые с помощью радиолокационных, оптических и многозональных систем наблюдения, являются важным источником информации о состоянии окружающей среды и природных ресурсах. В последние годы они все активнее используются при решении различных народнохозяйственных задач. Значительный рост использования данных ДЗЗ в различных сферах человеческой деятельности обусловлен следующим причинам: рост числа и многообразия искусственных спутников ДЗЗ [1–5, 7–9], появление новых сравнительно недорогих персональных станций приёма спутниковой информации типа «Лиана», «Селена», «СканЭкс», «СканЭр», и т. д. [4–6], интенсивное развитие коммуникационных сетей. Всё это позволяет оперативно доставлять на места использования информацию ДЗЗ, получаемую в любой точке Земли.

Доступность информации, как отмечалось выше, значительно расширяет круг задач народного хозяйства, при решении которых используется космическая информация [4, 6–8, 10]. Вот лишь некоторые из них:

- контроль состояния лесных массивов (определение оценки ущерба, нанесенного лесными пожарами, контроль уничтожения лесов в результате вырубок, инвентаризация лесов, выявление повреждений лесных массивов и др.);
- мониторинг паводковой ситуации (контроль затопленных территорий, определение степени загрязнения акваторий, мониторинг ледовой обстановки, определение площади поверхности водоемов, изменение очертаний береговых линий и др.);
- обнаружение разломов, зон разрывных нарушений;
- мониторинг добычи полезных ископаемых;
- выделение характерных объектов, таких как автомобильные и железные дороги, трубопроводы, линии электропередач и т. д.;
- коррекция карт местности по космическим снимкам.

Этот далеко не полный список задач объединяет одно — для их успешного решения требуется выделять на изображениях контуры объектов, иначе говоря, линейные структуры, линеаменты, такие как, береговые линии, разломы, границы лесных зон, городов, и других природных или техногенных объектов.

Так, при геологических исследованиях Земли из космоса выделение линий позволяет анализировать структуру земной коры — находить разломы, сейсмоактивные зоны, зоны разрывных нарушений, по которым можно судить о нахождении месторождений редкоземельных металлов и рудопроявлений.

При решении задач привязки космических снимков к имеющимся картам земной поверхности необходимым является выделение характерных объектов, таких как автомобильные и железные дороги, линии электропередач или границы объектов. Таким образом, алгоритмы выделения линейных структур оказываются достаточно полезными и в этой области.

Также алгоритмы выделения линейных структур находят применение при решении множества других задач, где требуется выделение границ между однородными областями. К таким задачам относятся задача инвентаризации сельскохозяйственных

удий, топографическое картирование, картографирование лесов, оценка ущерба, нанесенного лесным массивам, мониторинг наводнений.

Конкретизируем задачу выделения линейных структур (объектов). Под выделением линейных структур следует понимать такую обработку изображения, после которой с изображения убираются все элементы, не относящиеся к таким структурам. Дополнительной задачей такой обработки является нахождение координат этих структур, т.е. нахождение координат отрезков прямых, которые являются элементами линейных структур.

В данной главе подробно рассмотрен алгоритм выделения линейных структур на РЛИ, основанный на преобразовании Хаффа. Особенностью алгоритма является то, что алгоритм вместо пороговой обработки использует нейронную сеть Коханена.

### 13.1. Методы выделения линейных структур

Все задачи выделения линейных структур можно свести к обнаружению ярких прямых на темном фоне. Задачу обнаружение темных линий на более светлом фоне можно свести к описанной выше путем инвертирования изображения. Обнаружение границ объектов можно также реализовать путем предварительного пространственного дифференцирования изображения и последующего выделения линейной структуры. Линии могут быть как прямыми, так и представлять собой отрезки кривых. Далее будет рассматриваться только задача выделения на изображении отрезков ярких прямых линий.

Существует несколько способов выделения линейных структур на изображениях [12–14]:

- сегментация изображения по зонам одинаковой яркости или цвета и проведение границ между этими зонами;
- построение градиентного изображения и его пороговая обработка;
- метод, основанный на Фурье-анализе изображения;
- метод, использующий параметрический анализ.

Простейшим из перечисленных является метод, предполагающий сегментацию изображения по зонам с одинаковой интенсивностью («классам») [12, 13, 16] и проведение границ между этими зонами. Качество работы этого алгоритма определяется, в первую очередь, качеством кластеризации изображения. Увеличение качества кластеризации приводит к дополнительным вычислительным затратам [16], что резко снижает эффективность предложенного алгоритма. Кроме того, наличие шума на радиолокационных изображениях (спекл-шума) очень часто не позволяет добиться необходимого результата.

Следующий из перечисленных метод предполагает контрастирование перепадов, построение градиентного изображения и его пороговую обработку. Первая и вторая операция часто в процессе обработки бывают совмещены.

Построение градиента можно реализовать несколькими способами. Наиболее универсальный метод предполагает получение отсчета градиентного изображения  $G(i, j)$  через вычисление

$$G(i, j) = \max \left\{ |I(i, j) - I(i-1, j)|, |I(i, j) - I(i+1, j)|, |I(i, j) - I(i, j-1)|, |I(i, j) - I(i, j+1)| \right\}, \quad (13.1)$$

где  $I(i, j)$  – яркость исходного изображения в точке с координатами  $(i, j)$ , и нахождение максимальной разности. Однако в выражении (13.1) не учитывается направление вычисляемого градиента. Для устранения этого недостатка используются градиентные маски [5, 13], приведенные в табл. 1.






Рис. 13.1. Пороговая система обнаружения перепадов

Следует отметить, что фильтр Робертса вычисляет не вертикальные и горизонтальные составляющие градиента, а расположенные под углом сорок пять градусов к координатной сетке изображения.

Таблица 13.1

Примеры локальных градиентных фильтров

| Фильтр   | Горизонтальная компонента   | Вертикальная компонента   |
|----------|---|---|
| Робертса | $\begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}$                         | $\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$                         |
| Собела   | $\begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$  | $\begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}$  |
| Превита  | $\begin{bmatrix} 1 & 1 & 1 \\ 1 & -2 & 1 \\ -1 & -1 & -1 \end{bmatrix}$ | $\begin{bmatrix} 1 & 1 & -1 \\ 1 & -2 & -1 \\ 1 & 1 & -1 \end{bmatrix}$ |

Результаты выделения контуров с использованием фильтров Робертса, Собела и Превита на изображении, полученном космическим аппаратом *SPOT*, приведены на рис. 13.2.

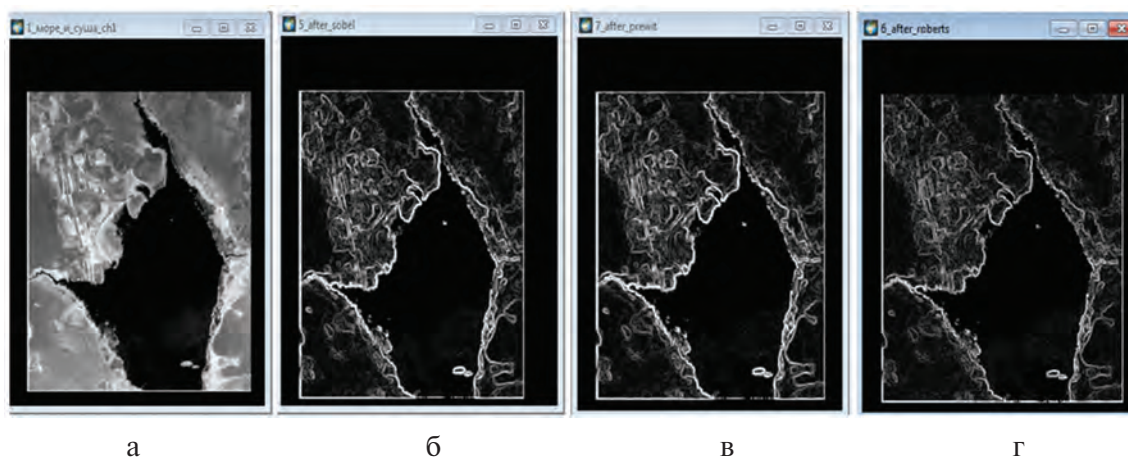


Рис. 13.2. Пример выделения контуров на изображении:

а — исходный снимок; б — изображение после фильтрации Собела;

в — изображение после фильтрации Превита; г — изображение после фильтрации Робертса

Из рисунка видно, что границы между областями с резко отличающимися яркостями достаточно хорошо идентифицированы. На менее контрастных участках изображения наблюдается достаточно много шумов. Это связано с относительно низким порогом, используемым на последнем этапе обработки. Если порог повысить, то многие контуры будут потеряны.

Кроме того следует отметить, что исходное изображение, которое использовалось в эксперименте, имеет достаточно высокое качество. Если же качество снимка существенно ниже (например, присутствует спекл-шум на радиолокационном изображении), то эффективность алгоритмов существенно снижается [14].

Метод построения градиентного изображения является частным случаем Фурье-анализа (спектрального анализа) изображения. Фурье-анализ изображений производится аналогично спектральному анализу сигналов, т.е. методами БПФ вычисляется спектральная плотность, затем автоматически или вручную отфильтровываются лишние составляющие, и производится обратное преобразование.

Этот метод можно использовать для подчёркивания линий, однако обработка обычно проводится с участием человека, т.к. необходим визуальный контроль процесса обработки, предполагающий выбор процедуры ВЧ-фильтрации. Но и в этом случае фильтр не всегда удается подобрать.

Описанные выше методы (за исключением первого) позволяют осуществить подчёркивание линий, но не способны вычислить их координаты и преобразовать растровое изображение в векторное. Алгоритмы параметрического анализа способны не только «найти» линии (их координаты), но и преобразовать их в векторный вид.

### 13.2. Алгоритм, основанный на преобразовании Хаффа

В [15] показано, что одним из наиболее эффективных алгоритмов обнаружения линияментов на изображениях является алгоритм, основанный на преобразовании Хаффа.

Преобразование Хаффа — это алгоритм параметрического анализа изображения. Алгоритм преобразует изображение в так называемое пространство Хаффа, где базисом являются параметры элемента изображения, в нашем случае — параметры прямой.

Данный подход предусматривает преобразование линии, заданной в декартовой системе координат, в точку в полярной системе координат. Прямую линию можно описать в параметрической форме в виде уравнения

$$\rho = x_i \cos \theta + y_i \sin \theta, \quad (13.2)$$

где  $x_i, y_i$  — координаты точек исходного изображения;  $\rho$  — расстояние, измеренное от начала координат по нормали к прямой, а  $\theta$  — угол наклона этой нормали относительно оси  $OX$ .

Как следует из формулы (13.2), образом точки при преобразовании Хаффа является кривая (рис. 13.3).

Если несколько точек изображения лежат на одной прямой, то при преобразовании все их образы пересекутся в одной точке (рис. 13.4).

Координаты точки пересечения ( $\rho_0, \theta_0$ ) и будут являться параметрами прямой на исходном изображении.

Таким образом, задача выделения прямых на изображении сводится к поиску точек пересечения кривых в пространстве Хаффа.




Рис. 13.3. Преобразование Хаффа для точки

С учетом сказанного выше традиционный алгоритм включает в себя следующие действия [15]. На первом этапе выполняется пороговое ограничение изображения по яркости. Такой шаг продиктован необходимостью исключения из обработки точек изображения, яркость которых лежит вне интересующего диапазона. Таковыми являются точки, принадлежащие фону, на котором производится обнаружение. Кроме того, на данном этапе удаляется информация о яркости точек, т.е. выходное изображение будет носить бинарный характер. В дальнейшем речь пойдет только о наличии или отсутствии точки.




Рис. 13.4. Преобразование Хаффа для прямой

Следующий шаг — преобразование Хаффа. Оставшиеся после пороговой обработки точки трансформируются (в соответствии с выражением (13.2)) в кривые на плоскости  $\rho - \theta$ . После дискретизации плоскости Хаффа формируется двумерный массив, размер которого определяется величинами дискретов по координатам  $(\rho, \theta)$ . Значение элементов массива равно количеству «кривых линий» (образов оставшихся

точек в декартовом пространстве), прошедших через данный дискрет. Таким образом, ячейки с большим весом определяют наличие и расположение на изображении интересующих прямых линий.

Поскольку вес ячеек получившегося массива равен длине соответствующей прямой, то исключение из изображения отдельных точек и линий, длина которых меньше интересующей, можно произвести путем пороговой обработки плоскости Хаффа. Порог ограничения определит минимальную длину обнаруженных прямых линий. В результате оставшиеся после ограничения ненулевые ячейки будут соответствовать прямым на изображении. Координаты ячеек ( $\rho$ ,  $\theta$ ) определяют положение прямой линии, а вес — ее длину.

Результатом работы всего алгоритма должно стать изображение, на котором присутствуют только прямые линии. Для этого на конечном этапе производится обратное преобразование Хафа путем переноса на выходное изображение только тех точек изображения, полученного после второй пороговой обработки, которые принадлежат прямым, соответствующим оставшимся ненулевым ячейкам плоскости  $\rho - \theta$ .

Основным недостатком данного алгоритма является то, что дважды используется пороговая обработка. Многообразие обрабатываемых изображений (разная съемочная аппаратура, различные сюжеты, существенно отличающиеся качественные показатели снимка и т.д.) требует индивидуального подхода к каждому снимку, что часто приводит к необходимости подбирать порог вручную для каждого изображения и практически делает невозможным автоматизацию процесса обнаружения линеаментов. Кроме того, наличие шумов и помех на изображениях существенно ухудшает эффективность алгоритма.

Частично устранить отмеченный недостаток можно, исключив первую пороговую обработку снимка [17]. Однако при этом возникает необходимость проводить преобразование Хаффа для всех точек изображения (не только для оставшихся ненулевыми после пороговой обработки в декартовой системе координат) и учитывать при формировании значений отсчетов в пространстве Хаффа также яркости точек исходного снимка.

Проведенная таким образом модификация алгоритма дает лучшие результаты при работе в шумах, а также дает возможность автоматизировать процесс обработки с помощью итерационного изменения оставшегося порога ограничения в плоскости Хаффа. Недостатком модифицированного алгоритма является большее, чем у базового, время обработки снимка.

Для минимизации отмеченных недостатков можно использовать нейросетевую обработку изображения, полученного после преобразования Хаффа. В предлагаемом алгоритме нейросетевая обработка будет совмещена с параметрическим анализом. Такая связка позволяет достаточно просто и вполне эффективно выполнить поставленную задачу.

Кроме того, как указывалось выше, нейронные сети сохраняют работоспособность и при зашумлении входных данных. Однако, как будет показано в дальнейшем, возникнет ряд других проблем, которые также предстоит решить.

Предлагаемый алгоритм состоит из нескольких этапов (рис. 13.5). Сначала производится преобразование Хаффа для анализируемого изображения. Далее изображение в плоскости Хаффа преобразуется в массив обучающих векторов для нейронной сети. На этом массиве происходит самоорганизация (обучение) сети конкурентного обучения, результатом самоорганизации являются веса нейронов на последнем этапе. Если работа сети организована правильно, то веса нейронов будут связаны известной зависимостью с параметрами прямых на исходном изображении. Тогда после самоорганизации сети эти параметры находятся, и прямые могут быть построены на отдельном изображении.

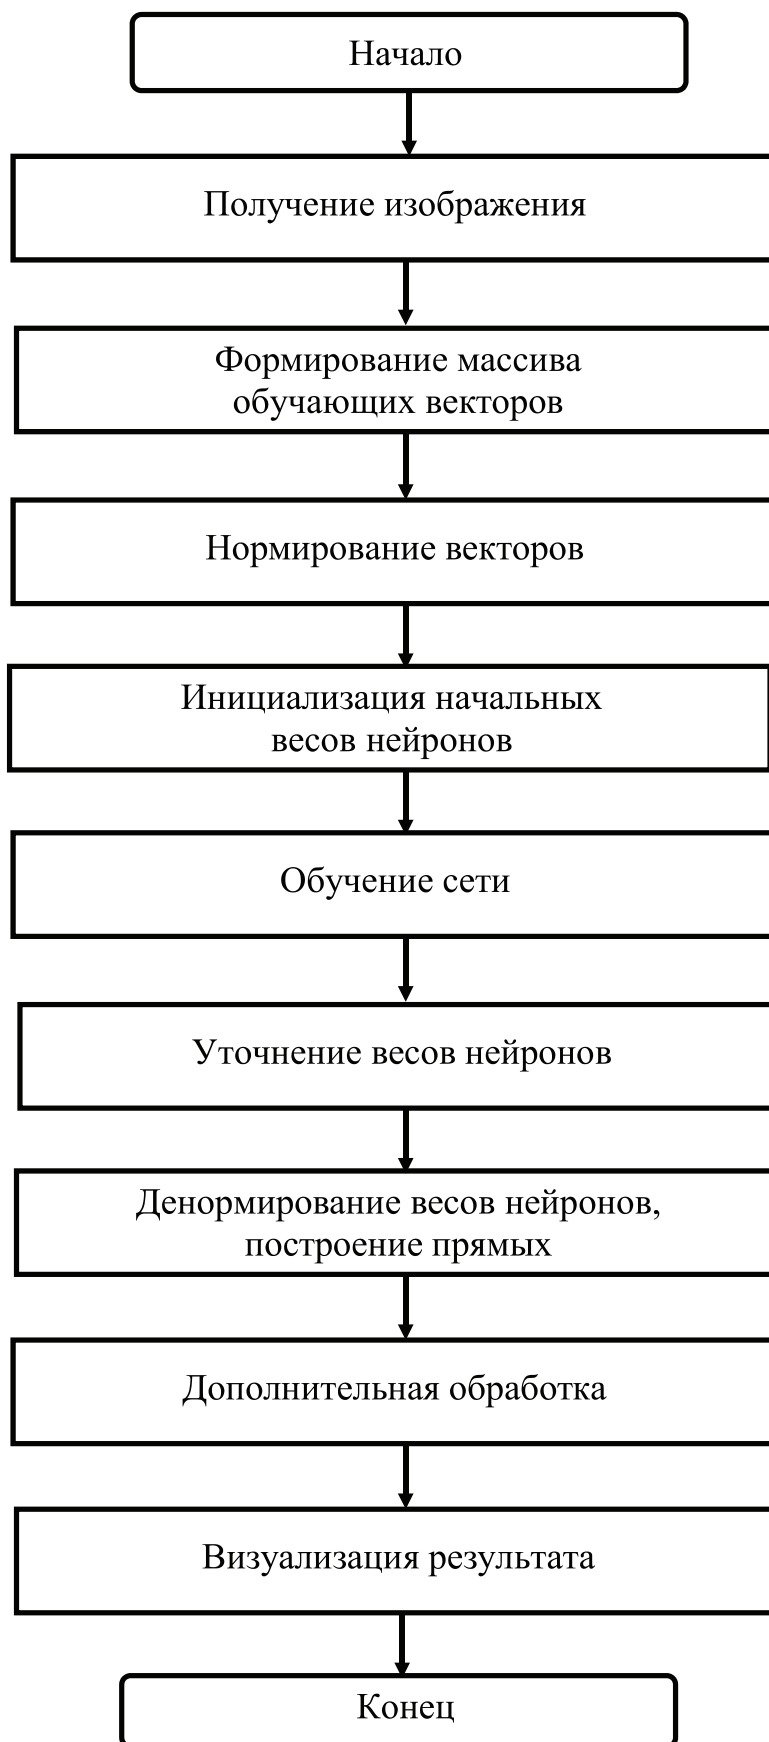


Рис. 13.5. Блок-схема модифицированного алгоритма



Теперь рассмотрим подробно каждый из этапов алгоритма.

На первом этапе для каждой точки исходного изображения с учетом ее яркости [17] осуществляется преобразование Хаффа в соответствии с выражением (13.2).

Диапазоны изменения параметров  $\rho$  и  $\theta$  зависят от расположения исходного изображения относительно начала декартовых координат. Если начало координат поместить в один из углов изображения, то параметр  $\rho$  будет изменяться от нуля до максимального значения  $\rho_{\max}$ , равного диагонали изображения:

$$\rho_{\max} = \sqrt{m^2 + n^2}, \quad (13.3)$$

где  $m, n$  – размеры изображения. А угол  $\theta$  будет изменяться в пределах от 0 до  $\pi/2$  радиан.

Если же поместить начало координат в центр изображения, то преобразование Хаффа будет выглядеть следующим образом:

$$\rho = \left( x_i - \frac{m}{2} \right) \cos \theta + \left( y_i - \frac{n}{2} \right) \sin \theta. \quad (13.4)$$

Параметры  $\rho$  и  $\theta$  в этом случае изменяются в следующих пределах:

$$\rho = 0 \dots \frac{\sqrt{m^2 + n^2}}{2}, \quad \theta = 0 - 2\pi. \quad (13.5)$$

Однако обработка плоскости Хаффа в непрерывном виде сопряжена с большими вычислительными трудностями: если исходное изображение имеет размер  $m \times n$  отсчетов, то для поиска всех пересечений потребовалось бы решить совместно  $(m \times n)/2$  нелинейных алгебраических уравнений.

Для упрощения поиска решения предлагается провести дискретизацию плоскости Хаффа [20]. Интервал дискретизации по каждому из параметров ( $\rho$  и  $\theta$ ) полученный экспериментально, исходя из компромисса между точностью и скоростью преобразования, равняется [18]: для параметра  $\rho$  – 1, для  $\theta$  – не менее  $0,02\pi$  рад. При таких интервалах дискретизации для изображения размером  $100 \times 100$  точек плоскость Хаффа будет содержать 142 000 ячеек. Уменьшению погрешностей также способствует выбор начала координат в центре изображения.

Изображение в плоскости Хаффа можно наглядно изобразить в изометрической проекции. В этом случае по вертикальной оси будет откладываться вес ячейки  $A(\rho_i, \theta_j)$ .

Для отрезка прямой (рис. 13.4) изометрия представлена на рис. 13.6.

Следует отметить, что высота пика (рис. 13.6) определяется количеством точек, которые образуют прямую линию исходного изображения. В этой связи линии исходного изображения, проходящие через весь снимок и расположенные в его углу, будут иметь пики в пространстве Хаффа, резко отличающиеся по своей амплитуде. При этом возникнут дополнительные проблемы дальнейшей обработки снимка. Чтобы устранить влияние длины линии на результат обработки необходимо провести весовую обработку (нормировку) отсчетов плоскости Хаффа [15].

Для рассмотренного на рис. 13.4 и 13.6 изображения максимум в точке  $(\rho_0, \theta_0)$  в пространстве Хаффа виден отчётливо, найти его без труда можно при помощи логических операторов.




Рис. 13.6. Изображение прямой (2D и 3D) в пространстве Хаффа

Для реального изображения максимумы будут растекаться (из-за обрабатываемого сюжета и дискретизации плоскости Хаффа [18, 19]), высоты их могут заметно отличаться, а в промежутках между ними будут присутствовать шумовые выбросы. Обработать такую картину при помощи логических средств крайне затруднительно, поэтому наиболее очевидным способом локализации максимума является пороговая обработка.

Однако, как указывалось выше, выбор порога производится визуально и для каждого изображения индивидуально, поэтому процесс поиска линейных структур становится не автоматическим, а полуавтоматическим. Кроме того, для обнаружения коротких или неярких линий порог должен быть установлен достаточно низко. В этом случае наблюдается «размывание» ярких линий, то есть вместо одной линии наблюдается пучок из большого числа линий со сходными параметрами (рис. 13.7).



Рис. 13.7. Размытие линий при пороговой обработке

Применение нейросетевой обработки изображения в пространстве Хаффа позволит избежать пороговой обработки, что сведёт указанные недостатки к минимуму.

Входной информацией любой нейронной сети являются обучающие вектора. Сети с самоорганизацией устроены так, что веса нейронов в результате обучения принимают значения, равные центрам скопления обучающих векторов. Этот процесс можно представить графически. Если обучающие вектора будут двумерными, а нейроны, соответственно, двухвходовыми, то положения обучающих векторов и текущих весов нейронов можно изобразить на координатной плоскости (рис. 13.8). Осями координат при этом будут являться компоненты векторов. Обучающие вектора на рисунке обозначены красными крестиками, а нейроны синими кружками.

При обучении (самоорганизации) сети происходит «втягивание» нейронов в области скопления данных. На рис. 13.8 это показано стрелками.

Изображение в плоскости Хаффа нужно преобразовать в массив обучающих векторов исходя из следующих требований:

1) Максимум в пространстве Хаффа и его окрестности должны преобразовываться в крупное скопление обучающих векторов.

2) Входные вектора должны быть нормализованы. Нормализация входных данных способствует более равномерному распределению нейронов по пространству обучающих векторов. В отсутствие нормализации алгоритмы обучения остаются работоспособными, но качество обучения ухудшается [22].

3) Для того, чтобы возможно было выполнить условие

$$\sum_{i=1}^{n+1} \vec{x}_i^2 = 1, \quad (13.6)$$

где  $\vec{x}$  — входной вектор;  $n$  — размерность пространства, входные данные должны быть предварительно масштабированы. Масштабирование само по себе обеспечивает сходимость любого из алгоритмов самоорганизации. Если какая-либо из компонент вектора принимает значения большие единицы, то процесс обучения будет расходиться, т.е. алгоритм будет неработоспособен.




Рис. 13.8. «Движение» нейронов при самоорганизации сети

Способов преобразования плоскости Хаффа в массив векторов может быть несколько. Один из них заключается в том, что каждой ячейке плоскости  $(\rho_i, \theta_j)$  ставятся в соответствие одинаковые вектора с координатами  $[\rho_i, \theta_j]$ , причём их количество равно весу ячейки  $A(\rho_i, \theta_j)$ . В этом случае общее количество будет определяться следующим образом:

$$N = \sum_{i=1}^{\rho_{\max}/\Delta\rho} \sum_{j=1}^{2\pi/\Delta\theta} A(\rho_i, \theta_j). \quad (13.7)$$

Для изображения размером  $100 \times 100$  точек количество векторов будет составлять величину порядка сотен тысяч. Однако для того, чтобы в последующем обучение проводилось достаточно эффективно, преобладание скоплений векторов над фоном должно быть более заметным. Для этого нужно ячейкам с большими весами сопоставлять значительно большее количество векторов,  $(A(\rho_k, \theta_m))^q$ , где  $q$  – коэффициент, равный 1,5–2,0. В этом случае ячейке с весом в единицу будет сопоставлен 1 обучающий вектор, ячейке с весом 10 – 31 обучающий вектор, а весу 100 – 1000 обучающих векторов (при  $q = 1.5$ ). Количество обучающих векторов  $N$  в этом случае может составлять свыше 100 миллионов. Для хранения такого объёма данных потребуется не менее 200 Мбайт памяти, а на обучение сети уйдёт значительное количество времени.

Более эффективен следующий способ. Он основан на том, что значения  $A(\rho_i, \theta_j)$  всегда квантованы. Если для каждого из уровней квантования выделить определенное количество обучающих векторов, то для нижних уровней (а из как правило большинство) несколько отсчетов  $A(\rho_i, \theta_j)$  будут представлены одним вектором, а на максимумы будет приходиться по несколько десятков векторов на один отсчет. Данный способ позволяет существенно сократить количество обучающих векторов, и, как следствие. Однако общее их количество всё равно останется достаточно большим, а это значит, что сеть будет обучаться продолжительное время.

Для дальнейшего снижения количества векторов можно использовать два момента:

Во-первых, весовые значения в пространстве Хаффа, расположенные ниже некоторого определенного уровня (например, ниже среднего значения всех ненулевых весов) можно не рассматривать. Максимумы обычно превышают этот уровень, однако иногда это может привести к пропуску коротких неярких линий.

Во-вторых, близкие уровни можно объединить и тем же количеством векторов представлять не один уровень, а группу уровней. При этом объединять в группу можно разное количество уровней.

Практически установлено, что количество векторов сокращается значительно [24].

Следующим этапом является нормализация обучающих векторов. Она предполагает два этапа. На первом этапе производится масштабирование компонент векторов по формулам:

$$x_1 = \left(1 \cdot N_{ang} \cdot \theta + 1\right) \cdot \frac{0,7}{\left(\frac{N_{ang}}{N_{norm}}\right)};$$

$$x_2 = \left(2 \cdot N_{norm} \cdot \rho - 1\right) \cdot 0,7,$$
(13.8)

где  $N_{norm}$  и  $N_{ang}$  – число дискретных отсчётов по нормали и углу соответственно.

Далее производится нормировка векторов путём добавления третьей компоненты по формуле

$$x_3^2 = 1 - x_1^2 - x_2^2.$$
(13.9)

В результате векторы становятся трёхмерными.

Перед началом процесса обучения инициализируются начальные веса нейронов. Возможно несколько вариантов инициализации (рис. 13.9):

- все веса одинаковые, например нулевые;
- нейроны располагаются упорядоченно (в виде «решётки»  $5 \times 10$  нейронов);
- веса инициализируются случайным образом.

Все три случая изображены на рис. 13.9.




Рис. 13.9. Инициализации весов нейронов:  
а — нулевые веса; б — упорядоченные веса; в — случайные веса

Если все начальные веса одинаковые, то для достижения нейронами удалённых скоплений может потребоваться большое количество циклов обучения, кроме того, за один цикл будет задействоваться лишь несколько нейронов, а остальные будут оставаться «мёртвыми». Поэтому несколько циклов потребуется только для того, чтобы «разбудить» нейроны. При случайной инициализации весов или при инициализации в виде «решётки» такой проблемы нет и скорости самоорганизации нейронной сети в этих случаях примерно одинаковые.

В нашем случае используется нейронная сеть с самоорганизацией конкурентного обучения (сеть Кохонена). Одним из наиболее быстрых алгоритмов обучения такой сети является алгоритм Мартинеса — Берковича — Шультена, или алгоритм нейронного газа [23].

В этом алгоритме на каждой итерации все нейроны сортируются в зависимости от их расстояния до вектора  $\vec{x}$ . После сортировки нейроны размещаются в последовательности, соответствующей увеличению удалённости от вектора  $\vec{x}$ :

$$d_0 < d_1 < \dots < d_{n-1}, \quad (13.10)$$

где  $d_k = \vec{x} - \vec{w}_{m(i)}$  обозначает удалённость  $i$ -го нейрона, занимающего в результате сортировки  $m$ -ю позицию в последовательности, возглавляемой нейроном-победителем, которому сопоставлена удалённость  $d_v$ . Значение функции соседства для  $i$ -го нейрона  $G(i, \vec{x})$  определяется по формуле

$$G(i, \vec{x}) = \exp\left(-\frac{m(i)}{\lambda}\right), \quad (13.11)$$

в которой  $m(i)$  обозначает очередность, полученную в результате сортировки ( $m(i) = 0, 1, 2, \dots, n-1$ ), а  $\lambda$  — уровень соседства. При этом уточнение веса  $i$ -го нейрона на  $k$ -м цикле обучения можно рассчитать по формуле (13.12)

$$\vec{w}_i(k+1) = \vec{w}_i(k) + G(i, \vec{x})\eta(k) [\vec{x} - \vec{w}_i(k)], \quad (13.12)$$

где  $\eta(k)$  — коэффициент скорости обучения.

Суть алгоритма уже была описана выше. Здесь рассмотрим последовательность действий, подбор параметров и «тонкие места» алгоритма.



Как видно из описания алгоритма, он имеет следующие параметры:

- тип метрики;
- число нейронов;
- число циклов обучения.
- пределы изменения коэффициента обучения  $\eta$ ;
- пределы изменения параметра  $\lambda$ .

Экспериментально установлено [24, 25], что выбор типа метрики не оказывает существенного влияния на качество самоорганизации, поэтому воспользуемся покомпонентной метрикой («Манхэттена»)

$$d(\vec{x}, \vec{w}_i) = \sum_{i=1}^N |\vec{x} - \vec{w}_i|, \quad (13.13)$$

так как она требует наименьших вычислительных затрат.

Число нейронов выбрать достаточно трудно. С одной стороны, их должно быть не меньше числа скоплений векторов, т. е. не меньше числа прямых на изображении. Уменьшение количества нейронов приведёт к пропуску линий. С другой стороны, избыточные нейроны обязательно приведут к ложно обнаруженным линиям, т. к. по окончании обучения они могут расположиться произвольно. Определить же количество линейных элементов до процесса самоорганизации не представляется возможным. Разумнее будет разрешить эту проблему в пользу избыточности нейронов. В таком случае число нейронов берётся заведомо выше возможного количества прямых на изображении.

Основным из достоинств алгоритма нейронного газа является то, что он сходится за меньшее число циклов по сравнению с алгоритмами *WTM* и *SOM*. Для того чтобы добиться высокой скорости самоорганизации, параметры  $\eta$  и  $\lambda$  делают не постоянными, а уменьшающимися с каждым циклом обучения. При выборе коэффициента обучения  $\eta$  необходимо учитывать, чтобы его значение в начале процесса обучения было меньше единицы (иначе алгоритм будет неустойчивым), а на последних этапах — не был слишком малым числом (тогда процесс самоорганизации будет слишком медленным или прекратится). Не рекомендуется брать этот коэффициент меньше 0,01. Экспериментально были выбраны следующие значения для  $\eta$ :

- начальное значение коэффициента  $\eta_0 = 0,99$ ;
- конечное значение коэффициента  $\eta_{\min} = 0,91$ ;
- способ изменения коэффициента — экспоненциальный.

Сложнее выбрать параметр  $\lambda$ . На начальном этапе обучения этот коэффициент выбирается так, чтобы при подаче входного вектора задействовалось как можно больше нейронов. Слишком большое значение  $\lambda$  приведёт к тому, что многие нейроны останутся «мёртвыми», при чересчур же малом значении  $\lambda$  нейроны будут хаотично перемещаться по пространству входных векторов.

В результате проведенных экспериментов было предложено следующее правило для изменения  $\lambda(k)$

$$\lambda(k) = \lambda_{\max} \left( \frac{\lambda_{\min}}{\lambda_{\max}} \right)^{k/k_{\max}}, \quad (13.14)$$

где  $k$  — номер итерации, а  $\lambda_{\max}$  и  $\lambda_{\min}$  должны принимать значения 3,0 и 0,05 соответственно.

Последний вопрос, который появляется при обучении сети, состоит в том, в каком порядке подавать входные вектора. Можно подавать вектора в том порядке, в котором они были созданы на предыдущем этапе. Однако в этом случае нейроны сначала за несколько циклов скапливаются около последнего предъявляемого вектора, а только затем начинают расходиться к скоплениям. В результате процесс обучения затягивается. Чтобы этого избежать, подавать вектора нужно в случайном порядке, который меняется перед каждым циклом обучения.

Таким образом, процесс обучения (самоорганизации) можно описать следующим образом. Сначала путём случайной перестановки определяется порядок подачи векторов. Затем вычисляются коэффициенты  $\eta$  и  $\lambda$  на данном цикле обучения. После этого с использованием попарной метрики «Манхэттена» определяются расстояния между первым предъявленным вектором и всеми нейронами, далее производится сортировка нейронов и вычисление функции соседства  $G(i, \vec{x})$  для каждого из них, и наконец, производится подстройка всех весов по формуле (13.12). Таким же образом обрабатываются все входные вектора, и на этом заканчивается один цикл обучения. Далее всё повторяется до тех пор, пока не пройдено заданное количество циклов.

Следует заметить, что увеличение скорости самоорганизации сети может привести к увеличению ошибок. В дальнейшем при денормировании весов нейронов ошибки могут быть заметны. Чтобы увеличить точность самоорганизации сети нужно для каждого случая экспериментально уточнять параметры  $\eta$  и  $\lambda$  и способы их изменения либо увеличивать количество входных векторов и число циклов обучения. Но это приводит к существенному замедлению процесса самоорганизации.

Поэтому после обучения сети рекомендуется провести ещё и «точную подстройку» весов. Она заключается в том, что после окончания основного процесса самоорганизации проводится ещё несколько циклов обучения, в которых подстройка весов осуществляется по формуле:

$$F(i, \vec{x}) = \exp(-ad), \quad (13.15)$$

где  $a$  — параметр, подбираемый экспериментально.

При этом для того, чтобы ускорить процесс настройки, на вход каждого из нейронов подаются не все вектора, а только те, что лежат в окрестности небольшого радиуса, например, 0,05. Количество циклов при настройке можно брать таким же, как и число циклов самоорганизации.

Параметр  $a$  в формуле (13.15) может быть постоянным или изменяться в зависимости от цикла обучения. Если параметр изменяется, то его первоначальное значение можно взять  $a_{\min} \approx 100$ , а при определении конечного значения необходимо учесть, чтобы «соседние» векторы оказывали минимальное влияние на процесс подстройки весов. А это зависит от интервала дискретизации параметров  $\rho$  и  $\theta$ . При значениях  $\Delta\rho$  и  $\Delta\theta$ , которые указаны выше ( $\Delta\rho = 1$ ,  $\Delta\theta = 0,02\pi$ ) величина  $a_{\max}$  будет примерно равна 500.

Этап «точной подстройки» приводит также и к тому, что если несколько нейронов оказываются вблизи одного скопления векторов, то в результате все они скапливаются в одной точке. Это способствует уменьшению количества ложно обнаруживаемых линий и упрощению последующей обработки (нейроны с повторяющимися весами удаляются). Но с другой стороны, ухудшается «разрешающая способность» алгоритма, т.е. из двух линий с близкими параметрами одна не будет обнаружена. Для улучшения разрешающей способности в данном случае необходимо уменьшать интервалы дискретизации параметров  $\rho$  и  $\theta$ .

Таким образом, после самоорганизации сети и «точной подстройки» весов нейроны находятся в центрах скоплений обучающих векторов, т.е. в максимумах на плоскости Хаффа. Часть нейронов остаются «мёртвыми» или «блуждающими» (т.е. не находят какого-либо скопления векторов), эти нейроны также исключаются из дальнейшей обработки.

Следующий этап, денормирование весов нейронов, наиболее простой. Здесь по весам нейронов  $\tilde{w}_i$  восстанавливаются параметры прямой линии  $\rho$  и  $\theta$ . Денормирование весов производится по формулам:

$$\begin{aligned}\rho_i &= \frac{\frac{w_2}{0,7} + 1}{2} \cdot N_R \Delta \rho; \\ \theta_i &= \frac{\frac{w_1}{0,7} + 1}{2} \cdot N_{ang}.\end{aligned}\quad (13.16)$$

После денормирования производится пересчёт параметров к стандартному уравнению прямой. Для случая, когда центр декартовых координат совмещен с центром снимка (размер которого  $m \times m$ ) пересчет будет проводиться по формуле:

$$y = \frac{m}{2} + \frac{\rho_i}{\sin \theta_i} - \frac{(x - m/2) \cos \theta_i}{\sin \theta_i}.\quad (13.17)$$

Теперь полученную прямую можно отобразить на изображении (рис. 13.10).



Рис. 13.10. Изображение, получаемое после денормирования весов

Из рис. 13.10 видно, что предложенный алгоритм достаточно точно определил прямую линию, на которой расположен обнаруживаемый объект (линеамент). Следующий и заключительный этап, позволяющий завершить решение поставленной задачи — это определение положения границ линейной структуры, обнаруженной нейросетевым алгоритмом.

Для решения обозначенной проблемы выполним синтез оптимального по методу максимального правдоподобия алгоритма выделения границ. При синтезе алгоритма будем рассматривать только отсчеты изображения  $I_k$ , расположенные вдоль линии,

выделенной при помощи описанной выше процедуры. Плотность вероятности интенсивности этих отсчетов (квадрата модуля) имеет экспоненциальное распределение, математическое ожидание которого пропорционально эффективной поверхности рассеяния наблюдаемого участка поверхности [3, 5]. Если на изображении обрабатываемой линии содержится  $L$  областей, отличающихся эффективной поверхностью рассеяния, то каждое выборочное значение наблюдаемого поля  $I_k$  имеет плотность вероятности  $W(I_k)$  соответствующей  $\Omega_l$ -й области радиолокационного изображения. Оптимальный по методу максимума функции правдоподобия алгоритм нахождения границы объекта заключается в вычислении функции

$$W(I/\Omega_1, \dots, \Omega_L) = \prod_{l=1}^L \prod_{j \in \Omega_L} W_l(I_k), \quad (13.18)$$

для всех допустимых границ между  $L$  областями и выборе такого значения, при котором выражение (13.18) максимально. Реализация такого алгоритма является весьма трудоемкой процедурой.

Существенного сокращения вычислительных затрат можно добиться, если допустить, что на изображении присутствует только один объект. В этом случае задача сводится к определению границ ( $c_1$  и  $c_2$  соответственно) между двумя областями с различными отражающими характеристиками (областью объекта и областью фона) [26].

Логарифм функции правдоподобия может быть записан в этом случае в виде:

$$\ln W(I/c_1, c_2, \sigma_0, \sigma_1) = \frac{1}{\sigma_0} \left( 1 - \frac{\sigma_0}{\sigma_1} \right) \sum_{k=c_1}^{c_2-c_1} I_k + (c_2 - c_1) \ln \left( \frac{\sigma_0}{\sigma_1} \right), \quad (13.19)$$

где  $\sigma_0, \sigma_1$  — средние значения сигнала в области фона  $\Omega_0$  и области объекта  $\Omega_1$  соответственно. Значения  $\sigma_0$  и  $\sigma_1$ , как правило, не известны заранее. В этом случае их можно вычислить, как

$$\hat{\sigma}_0 = \frac{1}{c_1} \sum_{k=1}^{c_1} I_k + \frac{1}{K - c_2} \sum_{k=c_2}^K I_k; \quad (13.20)$$

$$\hat{\sigma}_1 = \frac{1}{c_2 - c_1} \sum_{k=c_1}^{c_2} I_k \quad (13.21)$$

и подставить в выражение (13.19).

Решение о координатах границ  $c_1$  и  $c_2$  принимается по максимуму выражения (13.19).

После дополнительной обработки имеем картину, изображенную на рис. 13.11.

### 13.3. Пример обработки реального изображения

Рассмотрим поэтапно обработку изображения, полученного радиолокатором с синтезированной апертурой, установленном на борту спутника «Алмаз-1» (рис. 13.12). Особенностью радиолокационных изображений является наличие на них достаточно мощного мультипликативного шума (спекл-шума) [2, 3]. Это позволит проверить работу алгоритма в реальных условиях (при наличии помех на снимке).

На рисунке присутствуют изображения четырёх лесополос разной длины, а также яркий фрагмент в правом нижнем углу, граница которого по яркости незначительно превышает яркость самого объекта. Кроме того, на рисунке присутствует горизонтальная полоса средней яркости, являющаяся дефектом изображения




Рис. 13.11. Изображение, обнаруженного линеамента




Рис. 13.12. Фрагмент изображения, предложенный для обработки

После преобразования Хаффа и формирования массива обучающих векторов получаем картину, изображённую на рис. 13.13, где также показаны начальные веса нейронов (50 нейронов, расположение случайное).

По завершении 50 циклов обучения, и такого же количества циклов подстройки, денормирования весов нейронов и выделения границ линейных структур получаем картину, изображённую на рис. 13.14.

Можно видеть, что все прямые, присутствующие на изображении, обнаружены. Из неточностей можно отметить то, что правая прямая была обрезана с небольшой погрешностью, а также, что была обрезана ещё одна прямая — граница яркой области в правом нижнем углу, причём обрезана она была в том месте, где яркость границы снижается.






Рис. 13.13. Промежуточный результат обработки




Рис. 13.14. Итоговый результат

Проведенный эксперимент позволяет сделать вывод о работоспособности алгоритма и его хорошей помехоустойчивости.

#### 13.4. Литература к главе 13.

1. Шовенгердт Р.А. Дистанционное зондирование. Модели и методы обработки изображений. М.: Техносфера, 2010. 560 с.
2. Верба В.С., Неронский Л.Б., Осипов И.Г. и др. Радиолокационные системы землеобзора космического базирования / под ред. В.С. Вербы. М.: Радиотехника, 2010. 680 с.
3. Школьный Л.А., Толстов Е.Ф., Детков А.Н. и др. Радиолокационные системы воздушной разведки, дешифрование радиолокационных изображений / под ред. Л.А. Школьного. М.: Изд. ВВИА им. проф. Н.Е. Жуковского, 2008. 531 с.

4. Гарбук С.В., Гершензон В.Е. Космические системы дистанционного зондирования Земли. М.: Издательство А и Б, 1997. 296 с.
5. Коберниченко В.Г., Иванов О.Ю., Зраенко С.М. и др. Обработка данных дистанционного зондирования Земли: практические аспекты. / Под ред. В.Г. Коберниченко. Екатеринбург: Изд-во Урал. ун-та, 2013. 168 с.
6. УниСкан. Станция для приема данных со спутников ДЗЗ в диапазоне 8 ГГц. Описание и основные характеристики. М.: ИТЦ СканЭкс, 2010. 56 с.
7. Рис У.Г. Основы дистанционного зондирования. М.: Техносфера, 2006. 336 с.
8. Чандра А.М., Гош С.К. Дистанционное зондирование и географические информационные системы. М.: Техносфера, 2008. 312 с.
9. Кашкин В.Б., Сухинин А.И. Дистанционное зондирование Земли из космоса. Цифровая обработка изображений. М.: Логос, 2001. 264 с.
10. Воздушная разведка. Автоматизированное распознавание радиолокационных изображений. Монография / Под. Ред. И.К. Антонова. — М.: Радиотехника, 2021. 296 с.
11. Никольский Д.Б. Сравнительный обзор современных радиолокационных систем // Геоматика, № 1. 2008. С. 11–17
12. Гонсалес Р., Вудс Р. Цифровая обработка изображений. М.: Техносфера, 2006. 1072 с.
13. Яне Б. Цифровая обработка изображений. М.: Техносфера, 2007. 583 с.
14. Претт У. Цифровая обработка изображений: в 2 кн. М.: Мир, 1991. 792 с.
15. Дуда Р., Харт П. Распознавание образов и анализ сцен. М.: Мир, 1976. 507с.
16. Myasnikov, F.S., Ivanov, O.Yu. Preclassification of remote monitoring data in change detection tasks // AIP Conference Proceedings, 2020, 2293
17. Иванов О.Ю., Коркунов П.В. Алгоритм выделения линейных структур на изображениях, основанный на преобразовании Хаффа // Научные труды Международной МПК «СВЯЗЬ-ПРОМ 2005». Екатеринбург: ЗАО «Компания Реал-Медиа», 2005 стр. 96–101.
18. Ivanov O.Yu. Linear objects detection on SAR images // CEUR Workshop Proceedings, 2018, 2076, p. 58–65
19. Сосулин Ю.Г., Фам Чунг Зунг Нейросетевое распознавание двумерных изображений // Радиотехника и электроника, Том 48. № 2. 2003. С. 969–978
20. Ефремов В.В., Ефремова И.Н. О способах цифровой обработки изображений для снижения потерь от дискретизации и квантования // Известия юго-западного государственного университета. Серия: управление, вычислительная техника, информатика. Медицинское приборостроение, № 2. 2014. С. 52–60.
21. Sosnovsky A.V., Ivanov O.Yu. A neural network algorithm for linear structures detection on SAR images. // Proceedings 23th International Crimean Conference Microwave and Telecommunication Technology, CriMiCo'2013. 2013, p. 1263–1264.
22. Осовский С. Нейронные сети для обработки информации. М.: Финансы и статистика, 2004. 300 с.
23. С.Хайкин. Нейронные сети: полный курс.: Пер. с англ. М.: Издательский дом «Вильямс», 2006. 1104с.
24. Тарик Рашид Создаем нейронную сеть. М.: Издательский дом «Вильямс», 2018. 272 с.
25. Ivanov O.Yu., Vorobyova A.S. Study of neural network algorithm of the earth remote sensing data clustering. // Proceedings 24th International Crimean Conference Microwave and Telecommunication Technology, CriMiCo'2014. 2014, p. 1215–1216.
26. Доросинский Л.Г. Оптимальная обработка радиолокационных изображений, формируемых в РСА. М.: Издательский дом Академии Естествознания, 2017. 212 с.

Научное издание

Доросинский Леонид Григорьевич  
Виноградова Нина Сергеевна  
Иванов Олег Юрьевич

# ОБРАБОТКА РАДИОЛОКАЦИОННЫХ ИЗОБРАЖЕНИЙ

Монография



Технический редактор Кулакова Г.А.

Подписано в печать 17.12.2021

Бумага офсетная.

Гарнитура NewtonC

Формат 60×84 1/8

Печать трафаретная. Печ. л. 41,75.

Тираж 500 экз. Заказ № 43-21.

Отпечатано в типографии ИД «Академия Естествознания»,  
440026, г. Пенза, ул. Лермонтова, 3